

**SVEUČILIŠTE U SPLITU**  
**EKONOMSKI FAKULTET**

**DIPLOMSKI RAD**

**DETERMINANTE CIJENA ODABRANIH**  
**KRIPTOVALUTA**

**Mentor:**  
**dr.sc. Marko Hell**

**Student:**  
**Ante Crnogorac**

**Split, svibanj 2019.**

# SADRŽAJ:

1. UVOD .....	3
1.1. Problem istraživanja.....	3
1.2. Predmet istraživanja.....	5
1.3. Istraživačka pitanja .....	6
1.4. Ciljevi istraživanja .....	7
1.5. Metode istraživanja.....	7
1.6. Doprinosi istraživanja .....	8
2. OPĆENITO O KRIPTOVALUTAMA.....	9
2.1. Povijest i ideja kriptovaluta.....	9
2.1.1. Povijest novca i razmjene .....	9
2.1.2. Nastanak i pojam kriptovaluta .....	10
2.2. Osnovni pojmovi i proces rudarenja (mining) kriptovaluta.....	12
2.2.1. Blockchain koncept.....	13
2.2.2. Novčanik za kriptovalute .....	15
2.2.3. Rudarenje kriptovaluta.....	16
2.3. Najpoznatije kriptovalute.....	18
2.3.1. Bitcoin.....	18
2.3.2. Ethereum .....	20
2.3.3. Ripple.....	22
3. TEORIJSKA ANALIZA CIJENE KRIPTOVALUTA .....	24
3.1. Analiza provedenih istraživanja utjecaja na cijenu bitcoina .....	24
4. EMPIRIJSKA ANALIZA I REZULTATI .....	31
4.1. Definiranje uzorka i metodologija istraživanja.....	31
4.2. Definiranje zavisnih i nezavisnih varijabli.....	32
4.3. Analiza regresijskog modela .....	33
4.3.1. Definiranje modela.....	33
4.3.2. Deskriptivna statistika.....	35
4.3.3. Korelacija varijabli.....	36
4.4. Regresijska analiza.....	39
4.4.1. MODEL 1.....	40
4.4.2. MODEL 2.....	42
4.5. Interpretacija rezultata.....	44
5. ZAKLJUČAK .....	45
6. LITERATURA.....	47
POPIS TABLICA I SLIKA .....	52
SAŽETAK.....	53

# 1.UVOD

## 1.1. Problem istraživanja

Krajem prošlog stoljeća pojavio se prvi elektronski novac. Američki znanstvenik i kriptograf David Chaum osmislio je i iznio u svom radu 1983. godine ideju prvog anonimnog elektronskog novca i elektronskog novčanog sustava (Chaum, 1983). Godine 1998., računalni znanstvenik i kriptograf Nick Szabo dizajnirao je mehanizam za decentraliziranu digitalnu valutu, nazvanu Bitgold (Peck, 2012.). Iako mehanizam kao takav nikada nije implementiran, smatra ga se izravnom pretećom bitcoin arhitekture.

Kriptovalute definiramo kao digitalni novac, dizajniran da služi kao sredstvo razmjene, te koristi snažnu kriptografiju da zaštiti transakcije, kontrolira stvaranje novih jedinica i potvrđuje prijenos sredstava (Greenberg, 2011). Prva decentralizirana kriptovaluta pod nazivom Bitcoin, kreirana je 2009. godine od strane nepoznatog autora ili grupe autora pod pseudonimom Satoshi Nakamoto (Bitcoin Hrvatska, 27.8.2018.) Nakon razvitka Bitcoina, stvorena je podloga za razvoj drugih kriptovaluta. Vigna (2017) smatra da su sve alternativne verzije bitcoina takozvani altcoini. Takvo definiranje potvrđuje i Hankins (2018) koji altcoinom naziva bilo koju kriptovalu osim bitcoina. Tako su 2011. nastali su Namecoin i Litecoin, godinu poslije i Peercoin. 2013. godine razvio se Ethereum, danas druga vodeća kriptovaluta nakon Bitcoina. Prema CoinMarketCapu (27.8.2018.), do danas je razvijeno preko 1900 kriptovaluta, a njihov broj svakim danom raste.

Veliki rast popularnosti kriptovaluta osim tehnološkog napretka i inventivnog dizajna, temelj ima u želji mnogih za brzom i velikom zaradom (Sajter 2018). Naime, prema podacima s CoinMarketCapa (27.8.2018.) cijena Bitcoina u 2017. godini narasla je s 964 na 13580 američkih dolara, što je privuklo sve više špekulanata na kriptot tržište.

Trenutno vodeće kriptovalute s obzirom na tržišni udio su redom Bitcoin, Ethereum, XRP, Bitcoin Cash, Eos. Prema visini cijene, iza vodećeg Bitcoina, čija se cijena danas kreće oko 7200 američkih dolara, druga najveća kriptovaluta Bitcoin Cash kotira oko 620 američkih dolara. (CoinMarketCap, 27.8.2018.) Znatna razlika u cijeni vodeće kriptovalute i svih ostalih, daje nam motiv da istražimo što utječe na cijenu pojedinih kriptovaluta.

Cijenu kriptovaluta, kao i npr. Dionica, formira ukupno uloženi iznosi u nju. Što se više investira u nju, tj. što više ljudi zamjeni svoj novac za kriptovalu, vrijednost joj je veća (Rogina, 2018). Isti

autor također navodi da za razumjevanje formiranja cijene kriptovaluta, treba razlikovati dva pojma: Market capital (hrv. Tržišni kapital), koji dobijemo umnoškom ukupnog broja pojedine kriptovalute i jedinične cijene, te Circulation supply (hrv. Trenutačna zaliha) – ukupan broj jedinica pojedine kriptovalute u optjecaju. Cijena kriptovalute dobije se dijeljenjem tržišnog kapitala i trenutačne zalihe (Rogina, 2018).

S obzirom da su kriptovalute relativno nova pojava u svijetu, broj istraživanja povezanih s kriptovalutama i determinantama njihovih cijena nije velik. Poyser (2017) navodi dvije vrste faktora koje utječu na cijenu kriptovaluta: interne i eksterne. Glavni interni čimbenici su ponuda i potražnja, dok je eksterne čimbenike podijelio na kriptotržišne (atraktivnost, trend i špekulacije), makro-financijske (tečaj novca, kamatna stopa, cijena zlata i sl.), te na političke (legalnost, zabrane i sl.). Prema portalu Bitconnect (27.8.2018.), glavni pokretači cijene kriptovaluta su: ograničena ponuda i potražnja, energija u obliku električne energije koja se koristi za zaštitu podataka i rudarenje, korisnost valute, percepcija o njegovoj vrijednosti od strane javnosti, cijena bitcoina, mediji, prevare, pravna i vladina pitanja.

Najveći broj istraživanja do sada provedenih i dostupnih na internetu odnosi se na bitcoin, što je i logično s obzirom na popularnost Bitcoina kao najvrijednije kriptovalute danas.

Kavvadias (2017) proveo je regresijsku analizu vremenskih serija koje prate promjene cijene bitcoina. Uzorak je proveden na dnevnoj i tjednoj bazi u vremenskom periodu od 1. svibnja 2014. godine, do 12. lipnja 2017. godine. Kao zavisna varijabla postavljena je cijena Bitcoina. Hash rate, koji predstavlja mjernu jedinicu količine električne energije koju troši bitcoin mreža kako bi kontinuirano funkcionirala (Coinsutra), VIX indeks, tj. Indeks volatilnosti čikaške burze, portfelj svjetskog tržišta (S&P 500 i MSCI world), cijena zlata, obujam transakcija, količina bitcoina u optjecaju te trendovi uzeti su kao nezavisna varijabla. Kratkoročna dnevna analiza pokazala je da Hash rate i VIX indeks imaju negativan utjecaj na vrijednost bitcoina. Prema rezultatima kratkoročne tjedne analize, obujam transakcija i trendovi (korišteni Google trendovi) imaju pozitivan utjecaj na vrijednost bitcoina, dok VIX indeks i cijena zlata imaju negativan utjecaj. Dugoročna analiza pokazala je da cijena zlata i trendovi imaju negativan utjecaj na cijenu bitcoina, dok predstavnici svjetskog tržišnog portfolia (S&P 500 i MSCI world) imaju pozitivan utjecaj.

Kristoufek (2014) u svom radu analizira utjecaj pojedinih varijabli na tečaj između Bitcoina i američkog dolara. Kao faktore koji utječu na cijenu, između ostalog uzeo je atraktivnost kriptovalute, transakcijski obujam kriptovalute, te hashrate kao aproksimacija poteškoća u proizvodnji. Autor zaključuje da hashrate i transakcijski obujam imaju pozitivan učinak na cijenu

bitcoina, dok atraktivnost ima negativan utjecaj. Bouoiyour (2014) također zaključuje da hashrate ima pozitivan utjecaj na cijenu bitcoina, dok atraktivnost (trendovi) ima negativan utjecaj.

Hayes (2015) proveo je empirijsku analizu utjecaja troškova proizvodnje na vrijednost bitcoina. U regresijskom modelu određena su tri glavna pokretača cijena kriptovaluta, a to su poteškoće u rudarenju, stopa proizvodne jedinice i snaga kriptografskog algoritma. Sve tri varijable utječu na troškove proizvodnje, a naglasak je stavljen na trošak električne energije. Implikacije istraživanja pokazuju da sve što utječe na smanjenje troškova proizvodnje, ima negativan utjecaj na cijenu kriptovalute. Hayes navodi da će povećanje energetske učinkovitosti hardvera, smanjenje svjetske cijene električne energije te manje poteškoće u rudarenju smanjiti troškove proizvodnje, te imati negativan utjecaj na cijenu.

Ciaian et al. (2015) ističu cijenu nafte kao jedan od dva makroekonomska faktora koji utječu na cijenu. Također Palombizio and Morris (2012) navode da je cijena nafte glavni faktor koji stvara pritisak na troškove, te predstavlja glavni pokazatelj inflacije. U svoje istraživanje uključili su WTIndex, koji predstavlja cijenu sirove nafte, kao nezavisnu varijablu.

Polasik et al. (2014) u svom istraživanju, koristeći se podacima s Google trendinga, zaključuje da na cijenu bitcoina prvenstveno utječe njegova popularnost i transakcijske potrebe korisnika. Zaključuje da je trend statistički značajna varijabla, kao i broj transakcija, dok je povezanost između Bitcoinovih prinosa i fluktuacija glavnih valuta slaba i statistički beznačajna. Jenssen (2014) navodi da je odrednica cijene bitcoina rezultat potražnje za istim, uz ograničenu ponudu. Garcia et al. (2014) proveli su istraživanje na temelju podataka o bitcoinu i Google trendovima pretraživanja od sredine 2010. godine do 5. studenog 2013. godine. Zaključili su da povećanje pretraživanja pojma bitcoin negativno utječe na njegovu cijenu. Istraživanje je pokazalo da je za tri od četiri najveća dnevna pada cijena prethodilo prvo, četvrto i osmo povećanje volumena Google pretraživanja dan prije.

## **1.2. Predmet istraživanja**

U ovom dijelu definira se predmet koji će biti obuhvaćen u istraživanju. Detaljnim proučavanjem različitih istraživanja o temi kriptovaluta dolazi se do zaključka da je interes mnogih autora o cijeni kriptovaluta odnosno utjecajima formiranja cijene, najčešće bitcoina. Upravo su determinante cijene bitcoina bila jedna od najistraživanijih područja o toj tematici. Mnoge autore je zanimalo što to utječe na trenutačnu cijenu kriptovaluta. Kao što je već navedeno u predmetu istraživanja, različiti

autori su testirali razne nezavisne varijable koje prema njima imaju ulogu u formiranju cijene bitcoina. Tako Polasik et al. (2014) teoretski povezuje utjecaj popularnosti i transakcijske potrebe korisnika na cijenu bitcoina. Bouoiyour (2014) je pak zaključio da na cijenu bitcoina utječe hashrate, te atraktivnost kriptovalute. Kristoufek (2014), slično kao i Bouoiyour donosi zaključak da na cijenu bitcoina utječu varijable hashrate, atraktivnost kriptovalute, te transakcijski obujam.

Predmet ovog istraživanja su determinante cijene Ethereum i Ripplea, kao dvije kriptovalute koje uz već istraženi bitcoin čine više od 70% kriptotržišta. Istraživati će se koji faktori utječu na formiranje cijene navedene dvije kriptovalute, a koji pak nisu značajni. Dalje će se iščitati jačina i smjer utjecaja različitih faktora. U formiranje modela će biti uključeno više različitih autora kako bi se iskristalizirali samo faktori koji imaju određeno visoku vjerojatnost utjecaja na cijenu navedenih kriptovaluta.

O važnosti ove teme govori i cijena kriptovaluta koja je znatno porasla od stvaranja do danas. Tako je cijena Bitcoina od 2014. godine narasla sa 773 američka dolara na današnjih 6437 (CoinMarketCap, preuzeto 6.9.2018.). Na temelju toga možemo zaključiti o interesantnosti i važnosti ove teme za mnoge istraživače.

### **1.3. Istraživačka pitanja**

- Kako hashrate utječe na cijenu Ethereum?
- Kako cijena zlata utječe na cijenu Ethereum?
- Kako cijena zlata utječe na cijenu Ripplea?
- Ima li popularnost dobivena podacima s google trenda utjecaj na cijenu Ethereum?
- Kako popularnost utječe na cijenu Ripplea?
- Što predstavlja transakcijski obujam i kako utječe na cijenu Ethereum?
- Kako transakcijski obujam utječe na cijenu Ripplea?

Prema definiciji preuzetoj s blockchain.com, Hash rate predstavlja broj tera hasheva u sekundi koje proizvodi Bitcoin mreža. Hash rate je mjerna jedinica količine električne energije koju troši bitcoin mreža kako bi kontinuirano funkcionirala (Coinsutra, 7.9.2018.). Kristoufek (2014), Bouoiyour et al. (2014), Kavvadias (2017), između ostalih uzimaju hash rate kao varijablu koja ima znatan utjecaj na cijenu kriptovaluta.

Dyhrberg (2016) u svom radu ističe nek statističke sličnosti između kriptovaluta i zlata. Također,

Baur et al. (2017) navode sličnosti kriptovaluta i zlata, misleći na nestašicu, skupoću rudarenja, činjenicu da nemaju pokriće od vlade, te decentralizaciju. Upravo navedene sličnosti, ali i činjenica da su mnogi drugi autori (Bouoiyour (2014), Kavvadias (2017)) koristili cijenu zlata kao nezavisnu varijablu, čini cijenu zlata zanimljivim faktorom za uključivanje u istraživanje.

Nakon pretražene literature, te zbog dostupnosti podataka, odlučeno je da će biti istražen transakcijski obujam kriptovaluta kao jedan od faktora utjecaja na cijenu. Kavvadias (2017) i Kristoufek (2014) su u svojim istraživanjima također koristili ovu varijablu, ali isključivo na primjeru bitcoina. Transakcijski obujam predstavlja broj potvrđenih transakcija u danu pojedine kriptovalute.

Možda jedna od najkorištenijih varijabli u pregledanim istraživanjima na ovu temu svakako je popularnost kriptovalute, a većina autora koristi Google trendove kao relevantnu mjeru popularnosti. (Letra (2016), Kavvadias (2017), Polasik et al. (2014), Garcia et al. (2014). Iz tog razloga i u ovom istraživanju koristiti će se podaci s google trenda kao relevantni za informacije o popularnosti kriptovalute. U dosadašnjim istraživanjima, uglavnom su imali negativan utjecaj na cijenu kriptovalute.

#### **1.4. Ciljevi istraživanja**

Ciljevi istraživanja su definirani na temelju problema, predmeta i postavljenih istraživačkih pitanja ovog istraživanja. Cilj istraživanja svakako je spoznati trendove i događanja na tržištu kriptovaluta. Slična istraživanja na ovu temu već su provedena, s razlikom što će u ovom radu biti istražene determinante cijena druge dvije najznačajnije kriptovalute, ethereuma i ripplea, dok su dosadašnja istraživanja uglavnom temeljena na cijeni bitcoina. Istraživanje će dati odgovore na istraživačka pitanja. Istražiti će se utjecaj hash ratea, transakcijskog obujma, popularnosti i cijene zlata na cijenu ethereuma, te istih faktora izuzev hash ratea na cijenu ripplea. Također će se istražiti procjene drugih autora o budućnosti tržišta kriptovaluta, te analizirati prepreke i ograničenja s kojima se kriptotržišta suočavaju.

#### **1.5. Metode istraživanja**

Rad će se sastojati od dva dijela, teorijskog i empirijskog dijela istraživanja.

U teorijskom dijelu rada koristit će se sljedeće znanstvene metode: metoda analize i sinteze,

metoda klasifikacije i kompilacije, metoda deskripcije, induktivna i deduktivna metoda te metoda komparacije (Zelenika, 2000). U teorijskom dijelu rada koristit će se stručni i znanstveni radovi objavljeni u znanstvenim i stručnim časopisima, knjigama, portalima, te ostalim relevantnim izvorima. Za prikupljane podataka pretraživati će se različite baze podataka dostupnih na *CoinMarketCap*, *The World Bank*, *BitInfoCharts*, *GoldPrice.org*.

U empirijskom dijelu rada koristiti će se statistička metoda kako bi se dobili odgovori na istraživačka pitanja. Provesti će se regresijska analiza na temelju sekundarnih podataka o Ethereumu i Rippleu. Odabrane su dvije najvrijednije kriptovalute po tržišnoj kapitalizaciji, koje uz Bitcoin čine više od 70% tržišta kriptovaluta. Rad neće biti prostorno ograničen jer se radi o decentraliziranim vrijednostima na svjetskoj razini. Vremenski interval istraživanja biti će od 2016. godine do početka 2019. godine. Razlog tome je dostupnost cjelokupnih podataka o cijenama odabranih kriptovaluta za cjelovite godine na internetskoj stranici *CoinMarketCap*. U analizi će se koristiti 156 uzoraka, tj. vrijednost varijabli svakog petka kroz 3 godine. Dakle vremenska jedinica će biti jedan tjedan.

## **1.6. Doprinosi istraživanja**

Najveći doprinos ovog rada se očituje u nedostatku sličnih istraživanja. Gotovo sva istraživanja na temu determinanti cijene odnose se na bitcoin kao najpopularniju i najveću kriptovalutu. Ovaj rad će u obzir uzeti druge dvije najveće kriptovalute, ethereum i ripple. Kriptovalute su relativno novo područje koje se rapidno populariziralo na svjetskoj razini. Interes za kriptovalutama u današnje doba eksponencijalno raste što govori o sve većoj važnosti istraživanja u ovom područja. Različiti društveni subjekti traže odgovore na mnoga pitanja o temi kriptovalutama kako bi lakše postigli svoje ciljeve. Zbog puno bržeg rasta tržišta kriptovalutama nego što je očekivano mnoga od tih pitanja ostaju sve do danas neodgovorena. Pogotovo je zanimljivo pitanje formiranja cijene kriptovaluta. Ulagači ne posjeduju dovoljno informacija o mogućim utjecajima različitih faktora na cijenu kriptovaluta, pa često ulaze u velike rizike ne znajući čemu se prepuštaju. Takav način poslovanja utječe negativno i na cjelokupno društvo. Može se zaključiti da sva kvalitetna istraživanja na navedenu temu su korisna te mogu pomoći u boljitku kako osobnih, tako i društvenih interesa.



## 2. OPĆENITO O KRIPTOVALUTAMA

U posljednjem desetljeću svjetska javnost sve češće se susreće s pojmom kriptovaluta. Riječ je o vrsti digitalnog novca koji funkcionira putem kriptografskih algoritama utemeljenim na računalnim mrežama. U samoj primjeni kriptovalute nemaju svoj fizički oblik, te se koriste isključivo kao promjene zapisa na računima. Razlikuju se od običnih valuta u tome što nemaju centralizirani sustav kontrole, točnije ne postoji autoritativni centri koji stoje iza njih (Buterin et al. 2015).

U nastavku rada detaljnije će biti objašnjen pojam i razvoj kriptovaluta.

### 2.1. Povijest i ideja kriptovaluta

Kriptovalute predstavljaju digitalni novac nastao krajem prošlog desetljeća (Cunjak, Mataković, 2018). No, da bi razumjeli pojam i razlog nastanka kriptovaluta potrebno je poznavati povijest novca. Iz tog razloga u ovom dijelu prikazati će se kratka povijest nastanka "običnog" novca.

#### 2.1.1. Povijest novca i razmjene

U davnoj prošlosti potrebe za novcem nije ni bilo. Ljudi su svoje potrebe zadovoljavali razmjenom dobara. Oni koji su se bavili stočarstvom svoje proizvode razmjenjivali su s onima koji su se bavili ratarstvom i sl. Takva vrsta razmjene nazivala se trampa (Samuelson i Nordhaus, 2011). Takva razmjena funkcionirala je dok su obje strane imale koristi od nje. Međutim, došlo je do toga da su plemena mogla proizvesti više dobara nego što su ih mogla prodati, te su se javili viškovi. Pleša Puljić et al. (2017) navode da je društvo prošlo kroz tri procesa podjele rada.

Prvu veliku podjelu rada obilježilo je prostorno i vremensko razdvajanje proizvodnje i potrošnje. Do tada su ljudi uglavnom vršili razmjenu robe za robu, dok drugi proces podjele rada donosi razmjenu robe za robni novac (Segetlija et al. 2011). Robni novac kroz povijest je mjenjao kroz razne oblike, kao npr. Stoka, ulje, vino, bakar i sl.. Kasnije je robni novac ograničen samo na metale, te se takvim održao sve do 18. stoljeća. Novac u tom obliku imao je vrijednost zbog svoje rijetkosti, dok je ipak postojala mogućnost pronalaska rudnika tih metala (Samuelson i Nordhaus, 2011).

Treći proces društvene podjele rada započinje prestankom postojanja robnog novca, zbog pojave privatnog vlasništva. Kasnije je razvijen i papirnat novac, a već se spominje i sve veća potreba za elektronskim novcem (Babić et al., 2011).

Sve gore navedeno ukazuje nam na značajnost novca kroz razvoj civilizacije. Novac i danas ima ogroman utjecan na društvo, te praktički postajemo bezgotovinsko društvo. Očekuje se da će u

budućnosti e-novac, kojeg danas koristimo putem kreditnih i debitnih kartica gotovo u potpunosti zamijeniti gotovinu (Pleša Puljić et al., 2017).

Vodeći se navodima s portala Povijest.hr, možemo prikazati razvoj novca od samih početaka civilizacije do danas. Tako se kao prvo sredstvo razmjene spominje stoka oko 9000 godina prije Krista. Ljudi su koristili stoku, kako bi se olakšala razmjena i uklonile poteškoće u pronalasku onoga tko ima ono što tražiš, a treba mu ono što nudiš. U današnjem hrvatskom jeziku upravo zbog ovoga riječ blago označava stoku, ali i nešto vrijedno.

Četvrto tisućljeće prije Krista donosi nam plemenite metale, koji su zbog svoje rijetkosti i drugih svojstava razvijeni kao sredstvo razmjene. Prošlo je još tisućljeća prije nego se od njih počeo kovati metalni novac. Oko 1200. godine prije Krista zabilježena je upotreba puževih kućica kao novčanog sredstva. Najčešće su se koristile kućice morskih puževa zbog karakteristika. Problem je nastao kada su u nekim područjima izlovili puževe, za koje se teško stvarala kopija. U staroj Kini, oko 1000. godine prije Krista izrađivane su replike alata od bakra ili bronce. Takvim predmetima bi se pridodala simbolična vrijednost, te bi se koristile kao novac. U sedmom stoljeću prije Krista zabilježene su prve kovanice. Kovane od plemenitih metala koristile su se kao novac, a na sebi bi imale prikaze raznih bogova, vladara, životinja i sl. Glavna prednost ovakve vrste novca bila je trajnost materijala i slična veličina primjeraka. Papirnati novac pojavio se u Kini u 7. stoljeću. U početku se koristio samo za velike transakcije, a u 13. stoljeću postao je glavno sredstvo plaćanja u Kini. U Europi se pojavio tek u 17. stoljeću u Švedskoj. Banka Bank of England prva je 1821. godine uvela zlatni standard. Tako je imala pokriće da će za sav novac koji izda, isplatiti njegovu vrijednost u zlatu. Problemi za zlatni standard pojavili su se s rastom gospodarstva i broja stanovnika, što je uzrokovalo pad vrijednosti novca. Potreba za novcem tijekom Prvog svjetskog rata zadala je konačan udarac zlatnom standardu. Njujorški bankar John Biggins uveo je prve kreditne kartice 1946. godine. Nazvao ih je Charg-it, u prijevodu s engleskog Naplati to, te su se mogle koristiti u lokalnim trgovinama. Prve kredite kartice za opću namjenu uvedene su 1950. godine od strane Diners Cluba. Do današnjeg dana kartice su ostale jedan od najpopularnijih sredstava plaćanja. Konačno, nakon kratkog pregleda povijesti novca dolazimo do 2009. godine i razvoja Bitcoina, prve kriptovalute. O njoj će se više reći u nastavku rada.

### 2.1.2. Nastanak i pojam kriptovaluta

Financijska kriza uzrokovana kolapsom tržišta nekretnina u Sjedinjenim Američkim Državama, predstavljao je najveću depresiju nakon 1930. godine. Svi segmenti gospodarstva bili su obuhvaćeni

turbulencijama u financijskom sustavu. Kriza je dovela do nepovjerenja u financijske institucije, te monetarnu i fiskalnu politiku. Upravo to nepovjerenje ljudi dovelo je do ubrzanog razvoja inovativnih tehnologija za financijsko poslovanje (Cunjak i Mataković, 2018).

Cunjak i Mataković (2018) ističu posljednje desetljeće 20. stoljeća kao početak vrhunca digitalne revolucije, koji je vidljiv kroz pad cijena digitalnih komunikacijskih uređaja, te uključivanje interneta u kućanstva. U tim godinama pojavio se veliki broj sustava elektroničnog plaćanja na internetu, kao npr. CyberCash, First Virtual, DigiCash, Secure Pay, Web900 i drugi. Potaknute su internetske financijske aktivnosti, što je dovelo do pojave elektroničkog novca. Hamdi (2007.) definira elektronički novac kao sustav plaćanja u realnom i virtualnom svijetu. Isti autor navodi da je cilj elektroničkog novca unaprijediti efikasnost sustava plaćanja, te zamijeniti novčanice i kovanice u maloprodajnim transakcijama.

Jedan od razvijenih sustava elektroničkog plaćanja je i Peer-to-peer sustav. Prema Kaselj (2015), Peer-to-peer otvoreni je sustav i sastoji se od međusobno povezanih čvorova, koji služe za dijeljenje raspoloživih resursa. U sustavu je komunikacija izravna te ne postoji središnji autoritet. Predstavlja zapravo mehanizam transakcijske platforme u primjeni podvrste digitalnih valuta, kriptovalute (Cunjak, Mataković, 2018).

Prema Cunjak i Mataković (2018), kriptovaluta predstavlja ekvivalent elektroničkog novca. Glavna karakteristika su im kriptografski mehanizmi, pomoću kojih se stvaraju i bilježe transakcije putem privatnih i javnih ključeva. Ne postoji centralni autoritet koji služi za nadziranje transakcija, poput banke ili drugih financijskih institucija, već se transakcije odvijaju izravno između korisnika.

Takve transakcije odvijaju se na način da se svaka generira iz adrese koja je vezana za kriptografsku valutu, te predstavlja određeni ključ. Sve transakcije sadrže digitalni potpis. Da bi se stvorila sigurnost transakcija i onemogućilo krivotvorenje i zlouporaba bez originalnog privatnog ključa, potpis u svakoj poruci se razlikuje (Buturin et al., 2015). Iako se zbog sigurnosti koriste nove adrese, ne radi se ipak o potpuno anonimnim transakcijama, te ih je moguće povezati s adresom u svakom trenutku. Kaselj (2015) navodi da ipak postoje određene metode kako vladine organizacije i tajne službe mogu utvrditi korisnika određene adrese. To nam ukazuje na to da pseudonimnost nije provedena do kraja.

Kriptografski mehanizam nadograđen je blockchain tehnologijom. Ova tehnologija razvijena je za potrebe prve kriptovalute Bitcoina, ali je prepoznata i upotrijebljena i u drugim industrijama. U Bitcoin sustavu služi kao glavna knjiga u kojoj su pohranjene sve transakcije. Blockchain

omogućuje da se svaki novi zapis distribuira između čvorova u peer-to-peer sustavu u realnom vremenu (Cunjak i Mataković 2018). Hozjan (2017) navodi da se za identifikaciju sudionika te mogućnost čitanja i pisanja koristi kriptografija. To čvorovima sustava daje mogućnost dodavati i čitati podatke iz blockhaina. Više o blockchain tehnologiji biti će rečeno u nastavku ovog rada.

Kada govorimo o kriptovalutama, potrebno je naglasiti razlike između virtualnog novca i tzv. Fiat novca. Fiat novac je realni novac i prihvaćeno sredstvo razmjene u zemlji koja ga je izdala. Virtualni novac predstavlja zapravo fiat valute koje služe elektroničkom prijenosu. Međunarodna organizacija Financial Action Task Force definirala je funkcije virtualnog novca i to: 1.) sredstvo razmjene, 2.) jedinica za mjeru vrijednosti i 3.) pohranjuje vrijednost. Ističu da virtualni novac nije službeno sredstvo plaćanja ni u jednoj državi (Cunjak i Mataković, 2018).

Od 2008. godine, i pojave prve kriptovalute Bitcoina, razvijen je veliki broj drugih kriptovaluta. Prema podacima s *CoinMarketCap* na dan 11. ožujka 2019. godine postojalo je 2101 razvijena kriptovaluta, te 16238 razvijenih tržišta. U nastavku dio rada biti će posvećen za tri najveće kriptovalute po tržišnoj kapitalizaciji, Bitcoin, Ethereum i Ripple, a istraživanje će prikazati određene utjecaje na cijenu potonje dvije kriptovalute.

## 2.2. Osnovni pojmovi i proces rudarenja (mining) kriptovaluta

Kada istražujemo o kriptovalutama, naići ćemo na mnoge pojmove, najčešće na engleskom jeziku koji običnom laiku nisu poznati. Rogina (2017) na portalu kriptovaluta.hr, pisao je o osnovnim pojmovima vezanim za kriptovalute, a neke od njih iskoristit ćemo u nastavku.

**Blockchain** – o ovom pojmu detaljno će biti napisano u sljedećem podnaslovu, no svakako recimo da blockchain (hrv. lanac blokova) predstavlja kompletan popis svih transakcija. Osoba ne može potrošiti određenu jedinicu kriptovalute ako ju nije prethodno stekla, što dokazuje "glavna knjiga" (**ledger**).

**Node** – predstavlja svako računalo koje sadrži informacije o svim transakcijama.

**Mining** – proces kojim "rudari" (**mineri**) dolaze do pojedinog bloka transakcija u mreži. Za to su nagrađeni određenim iznosom od rudarene kriptovalute. Također o ovoj temi detaljnije će se reći u nastavku.

**Pow-Proof of Work** – označava određene matematičke algoritme koji se rješavaju rudarenjem, te se na taj način osigurava zaštita od hakerskih napada. Rudar koji prvi potvrdi blok transakcija dobiva iznos te kriptovalute.

**PoS-Proof of Stage** – kao i PoW, matematičkim algoritmom se osigurava zaštita kriptovalute, međutim tvorac bloka se ne utvrđuje na temelju toga tko je prvi potvrdio blok transakcija, već na temelju varijabli poput bogatstva korisnika. Rudari ne dobivaju nagradu, već direktnu proviziju od transakcije.

**Private key** – hrv. privatni ključ, kod sačinjen od kombinacije slova, brojeva i znakova koji služi za algoritme iz kojih se generira adresa korisnika.

**Software wallet** – hrv. softverski novčanik, predstavlja način na koji se pohranjuju kriptovalute unutar posebnog programa, putem raznih aplikacija za računala, mobilne uređaje i sl.

**Hardware wallet** – hrv. hardverski novčanik, zapravo je poseban uređaj, nalik USB-u, koji služi za pohranu kriptovaluta.

### 2.2.1. Blockchain koncept

Blockchain tehnologija kod kriptovaluta ima distributivnu ulogu između svih čvorova koji sudjeluju u sustavu. Ne postoji središnji autoritet koji kontrolira informacije koje se distribuiraju, iz razloga što svaki čvor održava svoju kopiju svake relevantne informacije. Na taj način pruža se maksimalna zaštita podataka korištenjem kriptografije. Blockchain koncept sastavljen je od niza blokova sastavljenih u lanac, odakle i naziv blockchain (hrv.lanac blokova). Ti blokovi povezuju se u lanac algoritmom pomoću kriptografske hash funkcije. Takvu vezu gotovo je nemoguće krivotvoriti (Hozjan, 2017).

Blockchain tehnologija predstavlja distribuiranu bazu podataka, tj zapise svih transakcija koje su izvršene među sudionicima. Svaka transakcija se provjerava konsenzusom većine sudionika, a nakon unosa u blok, zapisi se ne mogu brisati (Crosby et al., 2016). Cunjak i Mataković (2018) ističu ulogu Blockchaina kao glavne knjige u kojoj su zapisane sve transakcije, te ih je moguće provjeriti u bilo kojem trenutku.

Hozjan (2017) navodi neke osnovne značajke blockchain tehnologije, a to su:

- koristi se blockchain izgrađen prema modelu ravnopravnosti partnera (peer-to-peer)
- nema potrebe za centralnim autoritetom, decentraliziran sustav
- svaki novi zapis distribuiran je između čvorova u realnom vremenu
- koristi se kriptografija u svrhu identifikacije sudionika, potvrde identiteta, te korištenje mogućnosti čitanja i pisanja
- čvorovi sustava imaju mogućnost dodavanja podataka u blockchain

- čvorovi sustava imaju mogućnost čitanja podataka iz blockchaina
- ima razvijen mehanizam koji onemogućuje promjenu nad podacima koji su jednom upisani u blockchain, te omogućuje lako otkrivanje ukoliko zaista dođe do promjena

Crosby et al. (2016) objasnili su koncept blockchaina na primjeru Bitcoina, s obzirom da je i razvijen prvenstveno za tu kriptovalutu, no naglašavaju da je primjenjiv na sve digitalne transakcije na internetu. Kod internet trgovine javlja se treća strana kao posrednik kod transakcija, a najčešće je to neka financijska institucija. Zadatak joj je potvrditi transakciju, zaštititi je i očuvati njen povijesni zapis. Sve navedeno rezultira visokim troškovima transakcija.

Bitcoin koristi kriptografski dokaz umjesto povjerenja u treću stranu. Svaka transakcija zaštićena je ključevima, i to javnim ključem (engl. public key) primatelja, te privatnim ključem (engl. private key) pošiljatelja. Da bi vlasnik potrošio određenu jedinicu kriptovalute, mora dokazati vlasništvo nad privatnim ključem. Primatelj zatim provjerava digitalni potpis i vlasništvo nad privatnim ključem na način da provjeri javni ključ pošiljatelja te transakcije. Svaka provjerena transakcija zatim se unosi u glavnu knjigu. Provjera se odnosi na dvije stvari: 1.) treba dokazati da potrošač posjeduje kriptovalutu provjerom digitalnog potpisa na transakciji, 2.) provjeriti ima li potrošač dovoljno kriptovaluta na svom računu, provjerom svih transakcija s njegovog računa, ili provjerom javnog ključa registriranog u javnoj knjizi (Crosby et al., 2016).

Isti autori navode potrebu za mehanizmom koji će regulirati transakcije u mreži kako bi se izbjeglo dvostruko trošenje kriptovaluta, s obzirom da one ne dolaze istim redoslijedom kojim su generirane. Bitcoin je taj problem riješio upravo razvijanjem mehanizma, popularnog blockchaina.

Blockchain tehnologija funkcionira na sistemu da sustav naručuje transakcije stavljanjem istih u grupe koji se nazivaju blokovi, a zatim se svi ti blokovi povezuju u lanac, što čini tzv. Lanac blokova (engl. blockchain). Svaki blok sadrži transakcije koje su se dogodile u isto vrijeme, a blokovi su povezani u lanac linearno i kronološki (Crosby et al., 2016).

Crosby et al. (2016) ističu jedan problem kod blockchain mreže. Svaki čvor u mreži može prikupiti nepotvrđene transakcije i stvoriti blok, javlja se pitanje koji blok bi trebao biti sljedeći u lancu, s obzirom da može postojati više blokova s različitih čvorova koji su stvoreni u isto vrijeme. Taj se problem rješava uvođenjem matematičkih algoritama koje treba riješiti kako bi se postigao konsenzus, a naziva se "proof-of-work" (hrv. dokaz rada).

PoW funkcionira na način da rudari preko svojih računala rješavaju komplicirane matematičke zadatke, a onaj tko prvi riješi biva nagrađen određenim iznosom kriptovalute. Svrha svega je da se u

blockchain unese novi blok i pripadajuće transakcije. Ukoliko bi netko pokušao postaviti lažni blok u lanac, stvorio bi se novi lanac te bi se odabrao onaj duži kao ispravan (Živković, 2018).

### 2.2.2. Novčanik za kriptovalute

Novčanik za kriptovalute generalno predstavlja program namijenjen za sigurno pohranjivanje, primanje i slanje kriptovaluta, upravljanjem privatnim i javnim kriptografskim ključevima. Novčanici također pružaju opciju praćenja stanja kriptovalute, te automatiziraju određene funkcije kao što su procjena naknade koju treba platiti za postizanje određene transakcije (Hileman i Rauch, 2017).

Hileman i Rauch (2017) navode da svaka kriptovaluta posjeduje vlastitu implementaciju osnovnog novčanika (npr. Bitcoin Core za Bitcoin, Mist Browser za Ethereum i sl.). U posljednje vrijeme razvio se veliki broj pružatelja novčanika kako bi se olakšalo spremanje kriptovaluta. Novčanici su razvijeni od strane dobrovoljnih programera, ali i velikih korporacija koje su razvile svoje novčanike. Ukupan broj novčanika u 2016. godini narastao je za gotovo 4 puta, na 35 milijuna, u odnosu na 8.2 milijuna u 2013. godini.

Rogina (2017) ističe dvije osnovne podjele novčanika za kriptovalute, softverske i hardverske novčanike. Iz samog naziva lako je zaključiti razliku između navedenih. Softverski novčanik (engl. software wallet) jedan je od načina pohranjivanja kriptovaluta. Privatni ključ se čuva unutar posebnog programa, koji je instaliran u obliku aplikacije na razne elektronske uređaje poput mobitela, tableta i računala ili se otvara direktno preko Internet preglednika. Hardverski novčanik (engl. hardware wallet) predstavlja uređaj koji možemo usporediti sa svima poznatim USB-om, a dizajniran je i programiran za pohranu kriptovaluta. Mnogi korisnici upravo ovakve novčanike smatraju najsigurnijim načinom pohrane kriptovaluta.

Kripto novčanike također možemo svrstati u dvije glavne skupine; "vrući" i "hladni" novčanik. Novčanik koje je povezan s internetom naziva se "vrući", a onaj koji možemo koristiti izvan mreže naziva se "hladni novčanik". Hladni novčanici smatraju se sigurnijima, te se na njima preporučuje pohrana veće količine digitalnih kovanica. Vrući novčanik uglavnom se koristi u trgovini, kada je potreban česti pristup imovini (Sašo 2018).

Hileman i Rauch (2017) proveli su istraživanje na uzorku za koji vjeruju da predstavlja preko 90% ukupnog sektora novčanika za kriptovalute, te su došli do sljedećih zaključaka:

- postotak aktivnih novčanika varira između 7,5% do 30,9% ukupnog broja novčanika
- postoji između 5,8 milijuna i 11,5 milijuna aktivnih novčanika
- 81% pružatelja novčanika nalazi se u Sjevernoj Americi ili Europi, ali je samo 61% korisnika novčanika sa ta dva kontinenta
- 73% novčanika ne kontrolira privatne ključeve, što znači da nemaju pristup korisničkim fondovima
- 39% novčanika nudi opciju pohrane više kriptovaluta

Do danas je razvijen veliki broj kripto novčanika, a Sašo (2018.) navodi neke najpoznatije:

- Ledger – hladni novčanik, podržava više od 20 popularnih kriptovaluta;
- Trezor – hladni novčanik, podržava više od 10 popularnih kriptovaluta;
- MyCelium – vrući novčanik, podržava više od 10 popularnih kriptovaluta
- KeepKay – hladni novčanik, podržava više od 5 popularnih kriptovaluta
- Coinomi – vrući novčanik, podržava više od 50 popularnih kriptovaluta

### 2.2.3. Rudarenje kriptovaluta

Sve transakcije pojedine kriptovalute zapisuju se u glavnu knjigu, koja je zapravo lanac blokova. U njoj se može provjeriti bilo koja transakcija ikad napravljena u tom lancu. Da bi glavna knjiga bila sigurna ne smije postojati mogućnost da je netko izmijeni. Tu glavnu ulogu preuzimaju rudari. Kada se stvori transakcijski blok rudari ga kreću obrađivati. Upotrebom informacija iz bloka i korištenjem matematičke formule, informacije iz bloka pretvaraju se u niz slova i brojeva, tzv. "hash". Kako bi generirali hash, rudari osim informacija iz transakcijskog bloka koriste i hash prethodnog bloka u lancu. Na taj se način potvrđuje legitimnost svakog bloka u lancu i stvara digitalni pečat. Ukoliko bi netko pokušao krivotvoriti transakciju, promjena u jednom bloku izazvala bi lančanu reakciju do kraja lanca. Razlog tomu upravo je korištenje hash-a svakog bloka u stvaranju sljedećeg bloka (Hrvatski Bitcoin Portal).

U svakom kriptovalutnom sustavu ključnu ulogu imaju rudari koji su odgovorni za grupiranje nepotvrđenih transakcija u nove blokove, te njihovo dodavanje u glavnu knjigu "blockchain". Rudari osiguravaju potrebnu računalnu snagu kako bi osigurali blockchain računanjem velikog broja "hasheva" kako bi pronašli važeći blok. Svaki njihov uspješan blok koji dodaju u blockchain otežava potencijalnom napadaču reorganizaciju glavne knjige, te dvostruko trošenje neke već potvrđene transakcije. Rudari za svoj radi bivaju nagrađeni određenim iznosom rudarene



kriptovalute (Hileman i Rauch, 2017).

Hileman i Rauch (2017) ističu da se rudarstvo do danas razvilo od početnog hobija koji su pojedinci izvršavali na osobnim računalima do kapitalno intenzivne industrije koja koristi prilagođenu opremu i specijalizirane lance vrijednosti, koje možemo sažeti u pet kategorija prikazanih u tablici 1. Postoji mali broj proizvođača rudarske opreme koji opskrbljuju industriju. Razvijene su i organizacije koje nude usluge iznajmljivanja i održavanja potrebnih resursa za rudarenje, što omogućuje sudjelovanje u rudarskom procesu bez posjedovanja vlastite opreme. Razvijeni su i veoma profesionalizirani rudarski bazeni (engl. mining pool) koji nude podršku i dodatne usluge svojim korisnicima.

**Tablica 1: Sudionici rudarenja i njihove aktivnosti**

Aktivnost	Opis
Rudarstvo (engl. mining)	Osobe i organizacije koje koriste vlastitu opremu za obradu transakcija i zaradu od naknada za rudarenje.
Rudarski bazen (engl. mining pool)	Kombinira računalske resurse od većeg broja rudara kako bi se povećala vjerojatnost pronalaska novog bloka, a zatim dijeli nagradu za sudjelovanje u istraživanju rudarima na temelju količine udjeljenih računalnih resursa.
Proizvodnja rudarske opreme (engl. mining hardware manufacturing)	Organizacije specijalizirane za proizvodnju rudarske opreme,
Usluge rudarstva (engl. cloud mining service)	Organizacije koje iznajmljuju "hashing power" korisnicima,
Usluge održavanja opreme (engl. remote hosting services)	Organizacije koje organiziraju i održavaju opremu za rudarenje u vlasništvu korisnika.

Izvor: Izrada autora po uzoru na Hileman i Rauch (2017)

Rudari za glavni cilj imaju riješiti određenu matematičku zagonetku kako potvrdili novi blok i dobili nagradu. S obzirom da rudari dodaju sve više računalne snage, poteškoće u rješavanju tih zagonetki povećale su se. To dovodi do nastanka prvih bitcoin rudarskih bazena 2010. godine. Nagrade među rudarima koji su sudjelovali u istraživanju dijele se sukladno uloženoj računalnoj snazi koju je pojedini rudar pridonio bazenu. Povećanjem interesa za kriptovalutama, a time i cijena, došlo je do velikog ubrzanja u "naoružanju" rudara novijom i učinkovitijom opremom. Danas je rudarstvo postala konkurentna i resursno intenzivna industrija (Hileman i Rauch, 2017)

Prema Hilemanu i Rauchu (2017) određivanje mjesta na kojima će se postaviti objekti za rudarenje temelji se na tri ključna čimbenika: 1.) rudari moraju imati pristup jeftinoj električnoj energiji, 2.)

moraju imati pristup dovoljno brzom internetskom vezi za brzo primanje i emitiranje podataka s drugim čvorovima u mreži i 3.) da bi se rudarska oprema čuvala od visokih temperatura i pregrijavanja, traže se lokacije u zonama s nižim temperaturama, kako bi troškovi hlađenja bili niži. Sukladno tome, najviše rudarskih objekata nalazi se u prostorima gdje su ova tri čimbenika uglavnom zadovoljena. To se odnosi na Sjevernu Ameriku, Sjevernu i Istočnu Europu te Kinu. Kina je ujedno zemlja u kojoj je smješteno najviše rudarskih objekata, te koja koristi najveću snagu za rudarenje kriptovaluta u svijetu. Čak 58% ukupno broja svjetskih rudarskih bazena nalazi se u Kini, 16% u Sjedinjenim Američkim Državama, a preostalih 26% raspoređeno je na ostatak svijeta.

## 2.3. Najpoznatije kriptovalute

Nakon 2009. godine i nastanka prve kriptovalute Bitcoina, do danas se u svijetu razvilo ukupno 2112 kriptovaluta. Deset najvećih kriptovaluta po tržišnoj kapitalizaciji na dan 20.03.2019. godine prikazane su Tablici 2.

**Tablica 2: 10 vodećih kriptovaluta po tržišnoj kapitalizaciji**

Kriptovaluta	Tržišna kapitalizacija
Bitcoin	\$71.166.768.394
Ethereum	\$14.674.992.323
Ripple	\$13.145.304.160
Litecoin	\$3.678.994.970
EOS	\$3.392.223.101
Bitcoin Cash	\$2.826.862.122
Binance coin	\$2.169.363.530
Stellar	\$2.160.152.109
Tether	\$2.026.263.718
TRON	\$1.530.104.997

Izvor: Izrada autora prema podacima s [coinmarketcap.com](https://coinmarketcap.com)

### 2.3.1. Bitcoin

Bitcoin je prva i zasigurno najznačajnija kriptovaluta. Prvi put se spominje 2008. godine u članku "Bitcoin: A Peer-to-Peer Electronic Cash System", autora Satoshija Nakamota (Nakamoto, 2008). O autoru članka Nakamotu ne zna se gotovo ništa, a samo ime zapravo je pseudonim. Razvijene su brojne teorije tko je zapravo Nakamoto, a pretpostavlja se da je to zapravo tim stručnjaka koji je izmislio Bitcoin, Neki vjeruju i da je Nakamoto zapravo pojedinac koji se povukao zbog zaštite

svoje privatnosti, nakon što je glavnu ulogu prepustio Gavinu Andersonu, osobi koja sada vodi projekt Bitcoina (Kaselj, 2015).

Početkom 2009. godine Satoshi Nakamoto pokrenuo je projekt BitcoinQt, kojim je stvorena valuta bitcoin, te su prvi bitcoini pušteni u promet. Razvijena je Bitcoin peer-to-peer mreža, a započelo je i rudarenje bitcoina na dan 3.siječnja 2009. godine. U ranim danima vrijednost bitcoina bila je jako niska, a aktivnosti su se ogledale uglavnom u razmjeni između malog broja ljudi koje je zanimala kriptografija. Broj ljudi koji su rudarili bitcoin, kao i težina samog rudarenja, bio je nizak. Demian Lerner (2013.) navodi da je Satoshi Nakamoto izrudario oko 1 milijuna bitcoina, što je u to vrijeme iznosilo oko 10% ukupne količine. Iznenadujuće je da nijedan od tih bitcoina do danas nije potrošen. Međutim, kako su transakcije u blockchainu javne, smatra se da će se otvoriti trag prema identitetu Nakamota, s obzirom da će se stvoriti veza između računa koji kontrolira Nakamoto i neke osobe iz stvarnog svijeta (Franco, 2015).

Bitcoin je namjerno izgrađen kao decentralizirani sustav, što potvrđuju izjave Nakamoto (2009. u Franco 2015) gdje kaže: "Mislim da je bilo mnogo zainteresiranih za sustave 90ih, no nakon desetljeća neuspjelih sustava temeljenih na povjerenju u treću stranu, oni ih vide kao izgubljen slučaj.", te: "Bio bih iznenađen ako za 10 godina ne koristimo elektronsku valutu, sada kada znamo kako to učiniti."

Ukupan broj bitcoina ograničen je algoritmom na 21 milijun, a do danas ih je već izrudareno oko 17,6 milijuna. Kapoor (2016) navodi da se očekuje da će posljednji "satoshi", ili 0.00000001 bitcoin biti izrudaren do 2140. godine., s obzirom da se brzina rudarenja eksponencijalno smanjuje tijekom vremena.

Kako zapravo funkcionira Bitcoin?

Bitcoin mreža sastoji se od velikog broja računala, tj. čvorova koji su povezani. Prilikom kupnje bitcoina, svaki korisnik dobiva dva ključa, privatni i javni. Javni ključ predstavlja adresu, slično kao i email adresa, te je može dati bilo kojoj osobi za priman je valuta. Privatni ključ vlasnik koristi za slanje bitcoina (Kapoor, 2016).


Blockchain predstavlja zajedničku javnu knjigu na koju se oslanja cijela Bitcoin mreža. U nju se unose sve potvrđene transakcije, te pruža pregled svih transakcija korisnicima. Integritet i kronološki redoslijed blokova u lancu provodi se pomoću kriptografije. Za transakcije između dva Bitcoin novčanika koristi se privatni ključ koji služi kao potpis, te matematički dokaz da je transakcija došla od stvarnog vlasnika novčanika. Sve transakcije se emitiraju u mreži, a obično

budu ubrzo potvrđene kroz proces koji nazivamo rudarstvo. Rudarstvo predstavlja aktivnosti kojima rudari upotrebom računalne snage nastoje potvrditi transakcije, te ih uključiti u lanac blokova. Da bi transakcije bile uključene u lanac, moraju odgovarati strogim kriptografskim pravilima i biti potvrđene od mreže (Nakamoto, 2008).

### Bitcoin na tržištu

Prema podacima s CoinMarketCapa, cijena bitcoina na dan 22.3.2019. iznosila je 4.054.36 \$, a tržišna kapitalizacija 71.371.192.033 \$. Na današnji dan u prometu je 17.603.550 izrudarenih bitcoina, a konačan broj ograničen je na 21 milijun. Najveća cijena bitcoina zabilježena je na dan 17.12.2017., kada je iznosila 20.089 \$. ROI, tj povrat na investiciju ukoliko je netko kupio bitcoin u samom početku iznosi čak 2.897,57%.

### Bitcoin Charts



**Slika1: Graf cijene bitcoina**

Izvor: coinmarketcap.com

### 2.3.2. Ethereum

Prvi opis Etheruma dao je Vitalik Buterin krajem 2013. godine radeći na istraživanjima u Bitcoin zajednici. Ubrzo nakon toga Buterin objavljuje "White paper Ethereum", gdje je detaljno opisao i obrazložio tehnički dizajn, protokol i arhitekturu pametnih ugovora. Službena objava Etheruma uslijedila je na Sjevernoameričkoj konferenciji Bitcoina u siječnju 2014. godine. Nakon

zajedničkog rada i suradnje Buterina i Gavina Wooda, zajedno osnivaju Ethereum. Wood je u svom "Yellow paper Ethereum" objavio detaljnu specifikaciju rada virtualnog stroja Ethereum (EVM). Prema tim specifikacijama Ethereum je implementiran u sedam programa (C ++, Go, Python, Java, JavaScript, Haskell te Rust). Da bi se pokrenula zainteresiranost programera, rudara i investitora, Ethereum je najavio preprodaju svoje valutne jedinice ethereuma. Osnovane su pravne osobe koje su pripomogle u prikupljanju sredstava putem preprodaje, uključujući i Zakladu Ethereum (Stifung Ethereum) osnovanu u lipnju 2014. godine u Švicarskoj. U srpnju iste godine započela je 42-dnevna dodjela ethera, gdje se zamjenilo 31.591 bitcoin, tada vrijednih 18.439.086 \$, za oko 60.102.216 ethera. Zarada od preprodaje koristila se za vraćanje zakonskih dugova i ostale troškove. Iduću veliku preprodaju organizirali su Buterin, Wood i Jeffrey Wilcke putem svoje neprofitne organizacije ETH DEV. Tim ETH DEV radio je na promociji Ethereuma, a korisnička baza i promet konstantno su rasli. Razvijen je i DEVGrants program za nagrađivanje programera koji su doprinikli razvoju Ethereuma. Da bi postigli što veću sigurnost i stabilnost sustava, nudene su nagrade onima koji otkriju bilo kakve slabosti u softveru. Prva verzija mreže Ethereum Frontier pokrenuta je 30. srpnja 2015. godine. Rudari su se započeli pridruživati mreži kako bi pomogli oko osiguranja lanca blokova, te zarade ethera ([ethdocs.org](http://ethdocs.org)).

Ethereum je otvorena blockchain platforma koja nudi mogućnost izgradnje i korištenja decentraliziranih aplikacija zasnovanih na blockchain tehnologiji. S obzirom da je decentralizirana valuta, kao i kod Bitcoina, nitko ne kontrolira niti posjeduje Ethereum. Razlika s Bitcoinom očituje se u tome da je Ethereum dizajniran da bude prilagodljiv i fleksibilan. Nakon izdanja Homestead, druge glavne verzije platforme Ethereuma, svatko može koristiti te aplikacije ([ethdocs.org](http://ethdocs.org))

Kako Ethereum funkcionira?

Ethereum u svom djelovanju koristi slične značajke kao i Bitcoin, uz neke vlastite izmjene i inovacije. Bitcoin blockchain predstavljao je samo popis transakcija, Ethereumov blockchain prati stanje svakog računa. Kao i u Bitcoin mreži, korisnici plaćaju male transakcijske naknade mreži, kako bi se mreža zaštitila od zlonamjernih i neozbiljnih računalnih zadataka. Također, rudari provjeravaju i izvršavaju transakcije, natječući se da upravo njihov blok bude sljedeći dodan u lancu blokova. Za to dobivaju naknadu u vidu ethera, što im daje poticaj da sudjeluju u mreži Ethereum ([ethdocs.org](http://ethdocs.org)).

## **Ethereum na tržištu**

Prema podacima s CoinMarketCapa, cijena ethereuma na dan 25.3.2019. iznosila je 136,74 \$, a tržišna kapitalizacija 14.409.914.385 \$. Na današnji dan u prometu je 105.383.380 izrudarenih

bitcoina, a konačan broj nije ograničen kao kod bitcoina. Najveća cijena ethereuma zabilježena je na dan 13.01.2018. kada je iznosila 1.432,88 \$. ROI, tj povrat na investiciju ukoliko je netko kupio bitcoin u samom početku iznosi čak 4.728,97%.

## Ethereum Charts



**Slika2: Graf cijene ethereuma**

Izvor: coinmarketcap.com

### 2.3.3. Ripple

Ryan Fugger osnovao je tvrtku 2004. godine pod nazivom RipplePay. Osnovna ideja projekta bila je mreža povjerenja kod finansijskih odnosa koja bi zamijenila banke. Početkom 2011. godine Bitcoin je ipak bio dosta popularniji u odnosu na Ripple. Bitcoin je uspio izgraditi mrežu plaćanja, što je tada izgledala superiornija arhitektura u odnosu na Ripple. U svibnju 2011. godine Ripple timu pridružuje se Jed McCaleb, jedan od pionira Bitcoina, a nedugo iza Fugger mu je predao kompletan projekt Ripplea. Danas se kao jedan od suosnivača, te kao izvršni predsjednik Ripplea navodi Chris Larsen, kojeg je McCaleb angažirao 2012. godine. Kao glavni razlog dotadašnjeg neuspjeha projekta označena je nemogućnost povjerenja sudionika u strukturi ravnopravnih partnera. Da bi se riješio ovaj problem, formiran je "Ripple Gateway", tj. velike tvrtke kojima će ljudi moći vjerovati. Osnivači su smatrali da je to dobar kompromis između tradicionalnog bankarskog sustava i peer-to-peer mreže (bitmex.org., 2018).

Ripple je izdao prvu XRP kovanicu u siječnju 2013. godine. Temeljila se na javnom lancu kriptografskih potpisa kao i kod Bitcoina, te nije zahtijevao početnu mrežu povjerenja. Konačna ponuda XRP-a postavljena je na čak 100 milijardi. Mnogi smatraju da će to pomoći Rippleu u sprječavanju aprecijacije cijena. Tvrtki je dodijeljeno 80 milijardi, dok je 20 milijardi podijeljeno između tri osnivača. Larsen i McCaleb dobili su po 9,5 milijardi Ripplesa, dok je Arthur Britto dobio 1 milijardu (bitmex.org., 2018).

Osnovna razlika između Ripplea i dvije već spomenute kriptovalute Bitcoina i Ethereum je ta da se Ripplesi, digitalna valuta tvrtke Ripple ne rudari. Prilikom osnutka, određen je fiksni broj Ripplesa koji se neće povećavati, te nema potrebe za rudarenjem. Kako bi zainteresirao investitore, Ripple je odlučio da će zamrznuti 88% imovine, te prodavati milijardu XRP-a svaki mjesec (admiralmarkets.com.hr).

Kako Ripple funkcionira?

Ripple mreža je relativno velika mreža kod koje nemaju svi znanja o Rippleu te povjerenja u druge. Da bi se riješio taj problem koriste se lanci povjerenja, kao izravne ili neizravne veze između dva korisnika. Informacije se prenose putem protokola kojeg npr. Banke već koriste za sigurna online plaćanja kreditnim karticama. Nakon uplate mali vremenski period od 3 do 4 sekunde potrebno je da se ažuriraju knjige korisnika. Svaka transakcija se naplaćuje naknadom od 0,00001 XRP, a te naknade se unište, te na taj način profitiraju svi vlasnici Ripplesa smanjenem ukupnog broja Ripplesa (Cata, 2018).

## **Ripple na tržištu**

Prema podacima s CoinMarketCapa, cijena XRP-a na dan 26.3.2019. iznosila je 0,299651 \$, a tržišna kapitalizacija 12.497.419.047 \$. Na današnji dan u prometu je 41.706.564.590 Ripplesa, a konačan broj ograničen je na 100 milijardi. Ukupna količina trenutno iznosi 99.991.667.586 Najveća cijena XRP-a zabilježena je na dan 04.01.2018. kada je iznosila 3,84 \$. ROI, tj povrat na investiciju ukoliko je netko kupio bitcoin u samom početku iznosi čak 5.01,45%.

## XRP Charts



Slika3: Graf cijene XRP-a

Izvor: coinmarketcap.com

### 3. TEORIJSKA ANALIZA CIJENE KRIPTOVALUTA

Broj istraživanja provedenih na temu utjecaja na cijenu kriptovaluta siromašan je, a gotovo sva istraživanja dostupna na internetu odnose se isključivo na Bitcoin. Čitanjem dostupnih radova na ovu temu možemo uvidjeti da većina autora u svom istraživanju za zavisnu varijablu koristi cijenu Bitcoina, dok se nezavisne varijable nešto razlikuju kod autora. Varijable koje utječu na cijenu Bitcoina su transakcijski obujam, količina bitcoina u prometu, popularnost valute, indeksi s raznih svjetskih burzi, cijena zlata, te hashrate, definiran kao mjerna jedinica količine električne energije koju troši bitcoin mreža kako bi kontinuirano funkcionirala (Coinsutra).

#### 3.1. Analiza provedenih istraživanja utjecaja na cijenu bitcoina

Kavvadias (2017) u svom istraživanju utjecaja na vrijednost Bitcoina kao glavnu zavisnu varijablu koristi cijenu Bitcoina, dok je nezavisne varijable podijelio u tri kategorije. Prva kategorija odnosi se na tehnički aspekt Bitcoina i sadrži Hash rate, obujam transakcija i količinu bitcoina u optjecaju u trenutku istraživanja. Druga kategorija odnosi se na financijski aspekt Bitcoina i sadrži VIX indeks kao mjera volatilnosti čikaške burze, portfelj svjetskog tržišta (S&P 500 i MSCI world), te



cijenu zlata, dobivenu kao prosjek između dvije londonske tvrtke za fiksiranje cijene zlata, London Bullion Market Association (LBMA) i Handy & Harman. Treća kategorija sadrži pokazatelje popularnosti Bitcoina, a korišteni su podaci s Google trenda i Wikipedie. Podaci korišteni u istraživanju pribavljeni su iz javnih i nejavnih izvora, a odnose se na razdoblje od 1. svibnja 2014. godine do 12. lipnja 2017. godine. Iskorištena su 163 uzorka, na tjednoj bazi podataka zaključne cijene svakog petka u tom razdoblju.

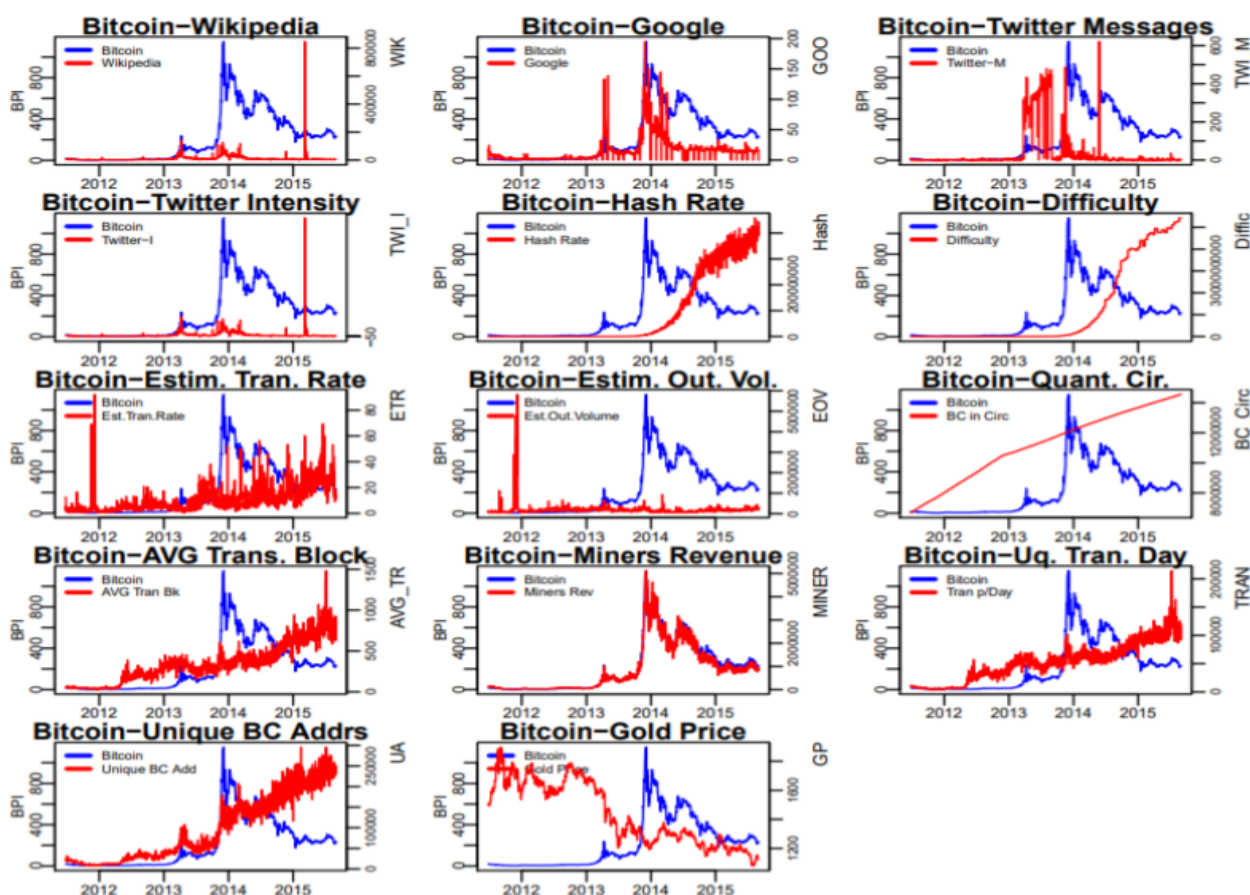
Isti autor proveo je regresijsku analizu vremenskih serija kako bi otkrio kratkoročni i dugoročni utjecaj čimbenika na cijenu Bitcoina. Autor je proveo istraživanje na dnevnoj i tjednoj bazi, te došao do rezultata o negativnom kratkoročnom utjecaju cijene zlata, VIX Indexa i Hash ratea. Google trendovi i volumen transakcija pokazali su pozitivan kratkoročni utjecaj na cijenu Bitcoina. Nakon provedene analize dugoročnog utjecaja na cijenu, autor zaključuje da Google trendovi i cijena zlata imaju negativan dugoročni utjecaj na cijenu Bitcoina, dok su S&P Index i MSCI World imali pozitivan utjecaj.

Letra (2016) u svom radu proveo je slično istraživanje utjecaja na cijenu Bitcoina kao predstavnika kriptovaluta općenito. Kao zavisnu varijablu postavio je cijenu Bitcoina izraženu u američkim dolarima (BPI), prikupljenu na dnevnoj bazi. Podatke za istraživanje autor je prikupio sa Wikipedie, Googlea, Blockchaina, te Quandla. Istraživanje je vremenski ograničeno na period od 26.6.2012. do 31.8.2015. godine. Podaci za istraživanje grupirao je u tri kategorije, i to: atraktivnost, ekonomske i tehničke, te makroekonomske čimbenike. U kategoriji atraktivnost Bitcoina iskorišteni su podaci dobiveni mjerenjem broja pretraživanja na broju Googleu (GOO) i Wikipediji (WIK), broj poruka na Twitteru sa znakom Bitcoin (TWI\_M), te automatska analiza mišljenja ljudi na Twitteru o pojmu Bitcoin (TWI\_I). U kategoriji makroekonomskih varijabli autor koristi cijenu zlata (GP), dok u kategoriju ekonomskih i tehničkih varijabli svrstava sljedeće nezavisne varijable:

- omjer volumena valute između tržišta zamjene i trgovine (engl. The exchange-trade ratio. (ETR)).
- ukupan broj transakcija u danu (engl. Estimate output value (EOV))
- ukupan broj bitcoina u opticaju, tj. miniranih do 31.8.2015. godine (BC\_Circ)
- prosječan broj transakcija po bloku (AVG\_TR)
- prihodi rudara (MINERS)
- ukupan broj jedinstvenih Bitcoin transakcija po danu (TRAN)
- broj jedinstvenih Bitcoin adresa korištenih po danu (UA)
- teškoća pronalaska novog bloka (engl. Difficulty (Diffic))

- Hashrate (HASH)

Nakon provedena tri GARCH(1,1) modela, autor je iz svog modela izbacio sve nezavisne varijable koje imaju jaku korelaciju, te se fokusirao na dvije varijable koje se odnose na atraktivnost Bitcoina, Google (GOO) i Twitter (TWI), te ukupan broj bitcoina u opticaju (BC\_Circ), kao tehničku varijablu. Pod pretpostavkom normalne distribucije, autor dolazi sljedećih rezultata uz 95% točnosti: Google pretraživanja (GOO) imaju vrijednost od  $-0.02546441$ , označavajući negativni blagi utjecaj na cijenu Bitcoina. Autor to objašnjava mišljenjem da se nestabilnost cijene smanjuje kako ljudi više traže pojam i povećavaju svoje znanje o Bitcoinu. Twitter (TWI) ima vrijednost od  $0.01361695$ , označavajući blagi pozitivan utjecaj na vrijednost Bitcoina, tj. Povećan broj "tvitova" na temu Bitcoina povećava i vrijednost same valute. Varijabla ukupnog broja bitcoina u opticaju ima vrijednost  $-0.00000738$ , ukazujući na blagi negativni utjecaj na cijenu Bitcoina kako se i očekivalo. Slika 4. prikazuje odnos zavisne i nezavisnih varijabli iz Letrina istraživanja.



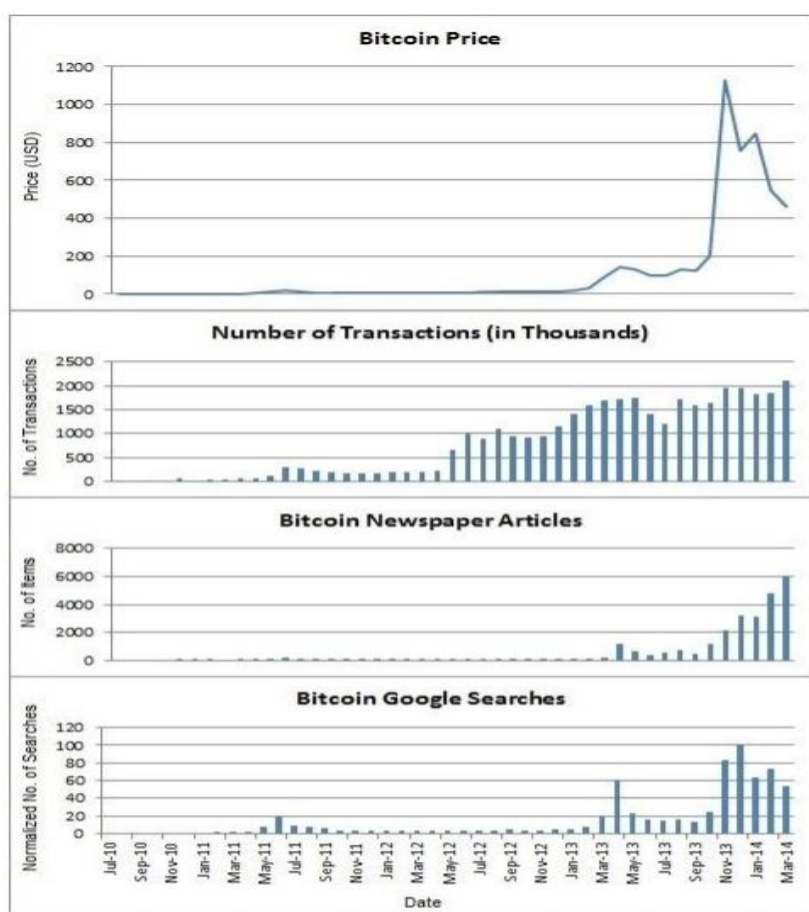
Slika4: Odnos zavisne i nezavisnih varijabli (Letra)

Izvor: Letra (2016)

Polasik (2014.) također je proveo istraživanje utjecaja na vrijednost Bitcoina. Prikupljeni podaci za

istraživanje vremenski su se odnosili na period od travnja 2011. godine do ožujka 2014. godine. Kao zavisna varijabla postavljena je cijena Bitcoina, dok su nezavisne varijable koje utječu na cijenu popularnost valute te ukupan broj transakcija. Popularnost valute odnosila se na rezultate s Google trenda koje potkrijepljuju pojam "Bitcoin", ali i poseban pokazatelj "Tone". Za bilo koji mjesec, sve vijesti na engleskom jeziku koje spominju riječ "Bitcoin" u Nexis bazi podataka su sakupljene u jednu tekstualnu datoteku. Učestalost pozitivnih i negativnih riječi u tim tekstualnim datotekama mjerena je prema formuli  $(\text{pozitivna negativna}) / (\text{pozitivna} + \text{negativna})$ .

Nakon provedene regresijske analize Polasik (2014) došao je do rezultata koji pokazuju da popularnost ima snažan utjecaj na vrijednost Bitcoina, bez obzira kako je definirana. Povećanje broja članaka u kojima se navodi Bitcoin povećava povrat za oko 31 do 36 baznih bodova. Bazni bod označava jednu stotinku postotnog poena. Google pretraživanja pojma Bitcoin također povećavaju prinos za oko 53 do 62 bazna boda. "Tone" je statistički značajan parametar, te pokazuje da novinski članci s negativnim prizvukom na ugled Bitcoina smanjuju njegovu cijenu, dok oni s pozitivnim komentarima djeluju pozitivno na cijenu. Povećanje ukupnog broja transakcija također je statistički značajna varijabla te ima pozitivan učinak.



Slika5: Odnos zavisne i nezavisnih varijabli (Polasik)

Izvor: Polasik (2014.)

Seys i Decaestecker (2016) u svom radu također su se bavili istim istraživanjem determinanti cijene Bitcoina. U svom istraživanju koristili su 1645 dnevnih opažanja u vremenskom periodu od 1.7.2011. do 31.12.2015. godine. Za zavisnu varijablu postavljena je cijena Bitcoina, dok su nezavisne varijable redom sljedeće: cijena sirove nafte na London Brentu, tečaj između američkog dolara i kineskoj juana, težina rudarenja, omjer razmjene. Količina pretraživanja na Wikipediji, obujam trgovine bitcoina u Kini, CFSI (The Cleveland Financial Stress Index<sup>2</sup>) i cijena zlata. Provedenim analizama autori dolaze do sljedećih zaključaka:

- cijena sirove nafte na London Brentu statistički je značajna, te ima negativni koeficijent od -0,23, što znači da porast cijene nafte za 1% utječe na pad cijene bitcoina za 0,23%
- USD/CNY tečaj također se pokazao kao značajan pokazatelj, s koeficijentom koji varira između -0,05 i -0,12. Konkretno, porast tečaja za 1% označava aprecijaciju dolara u odnosu na kineski juan i malim padom cijene bitcoina
- varijabla težina rudarenja postaje značajna pri razini signifikantnosti od 5%, kada se izostavi varijabla ukupnog broja bitcoina. U tom slučaju porast težine rudarenja za 1% označava blagi porast cijene bitcoina za 0,07%.
- unatoč očekivanjima da će omjer razmjene imati negativan utjecaj na cijenu bitcoina, autori nisu došli do takvog zaključka, uz pretpostavku da je razlog tomu što bitcoin nije službeno prihvaćeno sredstvo plaćanja
- količina pretraživanja na Wikipediji, prema autorima, također nema značajan učinak, suprotno istraživanjima Kristoufeka (2015.). To objašnjavaju tako što pozitivne vijesti utječu na povećanju potražnju za Bitcoinima, dok negativne smanjuju potražnju za istima, te se tako međusobno poništavaju
- unatoč očekivanjima da će obujam trgovine bitcoinima u Kini imati pozitivan utjecaj na cijenu bitcoina, autori nisu pronašli vezu između kineskog volumena i cijene bitcoina u USD. Razlog tomu navode veliku korelaciju između ove varijable i kontrolne varijable obujma trgovanja američkim bitcoinima
- s obzirom da je CFSI jedina varijabla u modelu bez logaritamske transformacije, promjene ove varijable za 1%, cijena bitcoina mijenja se 100 puta većim koeficijentom od ostalih. Očekuje se da će povećanje financijske neizvjesnosti pružiti pozitivnu stimulaciju za cijenu bitcoin-a, ali se ne može pronaći značajniji rezultat
- također, nije pronađen utjecaj cijene zlata na cijenu bitcoina.

U sljedećem dijelu biti će prikazane odabrane determinante za empirijsko istraživanje ovog rada. Radi lakše preglednosti, prijašnja istraživanja biti će prikazana u tablici za svaku determinantu pojedinačno.

#### **- Hashrate**

**Tablica 3: Determinanta Hashrate**

<b>Autor</b>	<b>Ovisna varijabla</b>	<b>Metoda</b>	<b>Uzorak</b>	<b>Učinak</b>
Kavvadias (2017)	Bitcoin	Višestruka regresija	tjedni uzorak - 1. 5. 2014. godine - 12. 6. 2017.	Negativan
Letra (2016)	Bitcoin	Višestruka regresija	dnevni uzorak 26.6.2011. - 31.8.2015	Nema utjecaj
Kristoufek (2014)	Bitcoin	Kvantilna regresija	14.9.2011 28.2.20	Pozitivan
Bouoiyour et al. (2014)	Bitcoin	Višestruka regresija	dnevni uzorak - 5.12.2010. - 14.6.2014.	Pozitivan

Izvor: Izrada autora

#### **- Cijena zlata**

**Tablica 4: Determinanta cijena zlata**

<b>Autor</b>	<b>Ovisna varijabla</b>	<b>Metoda</b>	<b>Uzorak</b>	<b>Učinak</b>
Kavvadias (2017)	Bitcoin	Višestruka regresija	tjedni uzorak - 1. 5. 2014. godine - 12. 6. 2017.	Negativan
Kristoufek (2014)	Bitcoin	Kvantilna regresija	14.9.2011 28.2.20	Nema utjecaj
Bouoiyour et al. (2014)	Bitcoin	Višestruka regresija	dnevni uzorak - 5.12.2010. - 14.6.2014.	Nema utjecaj

Izvor: Izrada autora

**Tablica 5: Determinanta Google trend**

<b>Autor</b>	<b>Ovisna varijabla</b>	<b>Metoda</b>	<b>Uzorak</b>	<b>Učinak</b>
Kavvadias (2017)	Bitcoin	Višestruka regresija- kratkoročna tjedna analiza	tjedni uzorak - 1. 5. 2014. godine - 12. 6. 2017.	Pozitivan
Kavvadias (2017)	Bitcoin	Višestruka regresija- dugoročna tjedna analiza	tjedni uzorak - 1. 5. 2014. godine - 12. 6. 2017.	Negativan
Letra (2016)	Bitcoin	Višestruka regresija	dnevni uzorak 26.6.2011. - 31.8.2015	Negativan
Kristoufek (2014)	Bitcoin	Kvantilna regresija	14.9.2011 28.2.20	Negativan
Bouoiyour et al. (2014)	Bitcoin	Višestruka regresija	dnevni uzorak - 5.12.2010. - 14.6.2014.	Negativan
Garcia et al. (2014)	Bitcoin	Vektorska autoregresija	sredina 2010.- 5.11.2013.	Negativan

Izvor: Izrada autora

**Tablica 6: Determinanta broj transakcija po danu**

<b>Autor</b>	<b>Ovisna varijabla</b>	<b>Metoda</b>	<b>Uzorak</b>	<b>Učinak</b>
Kavvadias (2017)	Bitcoin	Višestruka regresija- kratkoročna tjedna analiza	tjedni uzorak - 1. 5. 2014. godine - 12. 6. 2017.	Pozitivan
Polasik et al. (2014)	Bitcoin	Višestruka regresija	srpanj 2010.- travanj 2013.	Pozitivan
Kristoufek (2014)	Bitcoin	Kvantilna regresija	14.9.2011 28.2.20	Pozitivan

Izvor: Izrada autora

## 4. EMPIRIJSKA ANALIZA I REZULTATI

### 4.1. Definiranje uzorka i metodologija istraživanja

Kao što je prethodno navedeno, ovo istraživanje obuhvatilo je 156 uzoraka, konkretno u obzir su uzete zaključne cijene svakog petka u periodu od 8. siječnja 2016. godine do 28. prosinca 2018. godine. Za potrebe ovog rada korištena je desk metoda, odnosno sekundarni izvor podataka prikupljenih iz raznih baza. Podaci za zavisne varijable *Cijena Ripplea* i *Cijena Etheruma* prikupljene su iz baze podataka CoinMarketCapa. Podaci za nezavisne varijable prikupljeni su iz sljedećih izvora: Coinmetrics, Etherscan, GOLDPRICE i Google Trends.

Prilikom analize podataka sličnih ovima, autori su koristili različite metode. Tako Garcia et al. (2014) koriste vektorsku autoregresiju za izračun utjecaja varijabli na cijenu Bitcoina. Vektorska autoregresija (VAR) je stohastički procesni model koji se koristi za snimanje linearnih međuovisnosti među više vremenskih serija. Kristoufek (2014) u svom radu iskoristio je kvantilnu regresiju. Kvantilna regresija je produžetak linearne regresije i koristimo je kada uvjeti linearne regresije nisu primjenjivi. Također, postoji i panel analiza podataka. Za upotrebu višestruke regresije nužno je odlučiti se želi li se analizirati prostorna komponenta ili vremenska komponenta neke pojave. Panel analiza omogućava istovremeno analizirati više jedinica promatranja u nekom razdoblju. (Aljinović, Z., Marasović, B., 2012). Ostali autori uključujući Bouoiyour et al. (2014), Polasik et al. (2014), Letra (2016), Kavvadias (2017) u svojim istraživanjima koristili su višestruku linearnu regresiju. U ovom radu također je korištena regresijska analiza (višestruka regresija) kako bi se ispitao utjecaj odabranih determinanti na dvije zavisne, cijenu Etheruma i cijenu Ripplea. S obzirom da se u ovom radu istražuje utjecaj više nezavisnih varijabli na jednu zavisnu, upravo se metoda višestruke regresije nameće kao idealna za izračun utjecaja pojedinih varijabli na zavisnu. Višestruki regresijski model predstavlja algebarski model kojim se analitički određuje statistička povezanost jedne numeričke varijable s dvije ili više numeričkih varijabli. Model višestruke regresije koristi se zbog pretpostavke o linearnoj povezanosti jedne zavisne varijable i skupa nezavisnih varijabli (Jurun, 2007). Za provedbu regresije korišten je programski paket SPSS (Statistical Package for the Social Sciences). Također je u istom programskom paketu ispitana korelacija varijabli, kako bi se ispitao utjecaj jedne varijable unesene u model na drugu. Na temelju te dvije statističke metode donesen je konačan sud o utjecaju nezavisnih varijabli na zavisne kod oba modela.

## 4.2. Definiranje zavisnih i nezavisnih varijabli

U istraživanju su postavljene dvije zavisne varijable kroz dva modela istraživanja. Prvi model uključuje zavisnu varijablu cijena Ethereuma, te četiri nezavisne varijable: Hashrate, broj transakcija Ethereuma po danu, cijena zlata i google trend Ethereuma. Drugi model kao zavisnu varijablu ima cijenu Ripplea, a nezavisne varijable su broj transakcija Ripplea po danu, cijena zlata te google trend Ripplea.

Hashrate označava aproksimaciju poteškoća u proizvodnji, tj definiran je kao mjerna jedinica količine električne energije koju troši bitcoin mreža (u našem slučaju Ethereum mreža) kako bi kontinuirano funkcionirala (Coinsutra). Podaci za Hashrate preuzeti su iz baze podataka Etherscan.

Google trends je online alat za pretraživanje koji omogućuje korisniku da vidi koliko su često specifične ključne riječi ispitane u određenom vremenskom razdoblju. Google trends radi na način da analizira dio pretraživanja da bi izračunao broj pretraživanja koja su izvršena za određene pojmove u odnosu na ukupni broj pretraživanja na googleu u isto vrijeme (whatis.com).

Za podatke s Google trendsa vrijedi sljedeće: Trendovi prilagođavaju podatke pretraživanja radi lakše usporedbe pojmova. Rezultati pretraživanja proporcionalni su vremenu i lokaciji upita, a dobivaju se sljedećim postupkom:

- Svaka podatkovna točka dijeli se s ukupnim opsegom pretraživanja za geografsko područje i vremenski raspon koji predstavlja radi usporedbe relativne popularnosti. U suprotnom bi mjesta s najvećim opsegom pretraživanja uvijek bila najviše rangirana.
- Dobivene se brojke zatim izražavaju na skali od 0 do 100 na temelju proporcionalnosti teme u odnosu na sva pretraživanja o svim temama.
- Različite regije koje pokazuju isti interes za pretraživanje za neki pojam nemaju uvijek isti ukupni opseg pretraživanja. (support.google.com)

Izbor nezavisnih varijabli, tj determinanti cijena Ethereuma, odnosno Ripplea donesen je isključivo na osnovu prijašnjih znanstvenih radova koji su kao glavnu zavisnu varijablu imali Bitcoin, a vidljivi su i tablično prikazani ranije u dijelu 3.1. S obzirom da su Ethereum i Ripple, uz Bitcoin, vodeće kriptovalute na tržištu vodio sam se idejom da bi mogli imati i slične determinante koje utječu na formiranje cijene. Korištena je metoda sekundarnog prikupljanja podataka sa raznih dostupnih online izvora.



**Tablica 7: Zavisne i nezavisne varijable u istraživanju**

	<b>VARIJABLA</b>	<b>OZNAKA MODELU</b>	<b>U IZVOR</b>	<b>OČEKIVANI UTJECAJ</b>
<b>ZAVISNA VARIJABLA</b>	Cijena Ethereum	ETH	Coinmarketcap	/
	Cijena Ripplea	RPL	Coinmarketcap	/
<b>NEZAVISNA VARIJABLA</b>	Hashrate	HASH	Etherscan	Pozitivan
	Cijena zlata	GOLD	GoldPrice	
	Broj transakcija Ethereuma po danu	TPDE	Etherscan	Pozitivan
	Broj transakcija Ripplea po danu	TPDR	Coinmetrics	Pozitivan
	Google trend Ethereuma	GTE	Google Trends	Negativan
	Google trend Ripplea	GTR	Google Trends	Negativan

Izvor: Izrada autora

### 4.3. Analiza regresijskog modela

U ovom radu korištena je višestruka regresija da bi se ispitaio utjecaj odabranih determinanti na cijenu Ethereum, odnosno Ripplea. Model višestruke regresije osnovni je algebarski model, te najčešće korišten model u praksi kojim se proučava povezanost jedne zavisne varijable ( $y$ ), te dviju ili više nezavisnih varijabli ( $x_i$ ). Prvi korak u analizi je utvrđivanje svojstava varijabli i parametara, a zatim se prelazi na procjenu parametara, varijance, standardne devijacije i drugih statističkih pokazatelja. Zatim slijede postupci ispitivanja hipoteza i kakvoće dobivenih rezultata (Novak, 2008).

U primjeni regresijske analize u ovom istraživanju koristiti ćemo dva modela, a razlog tomu je postojanje dvije zavisne varijable prilikom postavljanja naših istraživačkih pitanja. Za svaku od njih pojedinačno provesti ćemo regresijsku analizu i analizu korelacije varijabli kako bi procijenili utjecaj odabranih varijabli na cijenu Ethereum u jednom modelu, odnosno Ripplea u drugom.

#### 4.3.1. Definiranje modela

Opći oblik modela višestruke regresije glasi:

$$\hat{y} = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k + e, \quad (1)$$

gdje su:

$\hat{y}$  – zavisna varijabla,

$X_1, X_2, \dots, X_k$  – nezavisne varijable,

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$  – parametri koji se procjenjuju

$e$  – slučajna greška.

Modeli korišteni u ovom istraživanju su sljedeći:

### MODEL 1

$$ETH = \beta_0 + \beta_1 HASH + \beta_2 GOLD + \beta_3 TPDE + \beta_4 GTE, \quad (2)$$

gdje su:

ETH – cijena Ethereuma

HASH – Hashrate

GOLD – cijena zlata

TPDE – broj transakcija Ethereuma po danu

GTE – google trend Ethereuma

Konačni oblik modela 1 poprimiti će drugi oblik, te će sadržavati jednu nezavisnu varijablu manje, izbačenu iz modela zbog manjka statističke značajnosti u odnosu na zavisnu varijablu. Radi se o varijabli Google trend Ethereuma, te će MODEL 1 poprimiti sljedeći konačan oblik:

$$ETH = \beta_0 + \beta_1 HASH + \beta_2 GOLD + \beta_3 TPDE \quad (3)$$

### MODEL 2

$$RPL = \beta_0 + \beta_1 GOLD + \beta_2 TPDR + \beta_3 GTR, \quad (4)$$

gdje su:

RPL – cijena Ripplea

GOLD – cijena zlata

TPDR – broj transakcija Ripplea po danu

GTR – google trend Ripplea

#### 4.3.2. Deskriptivna statistika

Deskriptivna statistika poslužit će nam za jasnije razumjevanje podataka varijabli unesenih u istraživanje, te prikazivanje nekih osnovnih statističkih pokazatelja. Deskriptivni statistički pokazatelji prikazani su kroz tablice radi bolje preglednosti, uz dodatan opis svake pojedine varijable.

**Tablica 8: Deskriptivna analiza zavisnih varijabli**

	cijena Etheruma \$	cijena Ripplea \$
N Valid	156	156
Missing	0	0
Mean	238,4034410	,2978487
Median	149,0250000	,1921875
Std. Deviation	278,66085813	,43266104
Minimum	,98679	,00511
Maximum	1273,20000	3,05

Izvor: Izrada autora

Cijena Etheruma u modelu 1, te cijena Ripplea u modelu 2 zavisne su varijable u ovom istraživanju. Tablica 8 prikazuje deskriptivnu statistiku zavisnih varijabli. Uzorak svake varijable čini 156 podataka. Iz tablice je odmah lako uočiti velike razlike u cijenama jedne i druge promatrane kriptovalute. Visoka standardna devijacija kod cijene Etheruma od 278,66 govori nam o visokom odstupanju cijena od prosjeka kroz 156 promatranih vremenskih jedinica. Kod Ripplea to nije slučaj, te standardna devijacija iznosi 0,43, što govori da nije značajna razlika u cijenama u promatranom periodu. Prosječna cijena Etheruma iznosi 238,40 \$, najniža cijena 0,9868 \$, dok najviša iznosi 1273,20 \$. Prosječna cijena Ripplea iznosi 0,2979\$, najniža 0,0051 \$, a najviša zabilježena cijena iznosila 3,05 \$. Medijan cijene Etheruma iznosi 149,03 \$, te nam govori da je polovina cijena u cjelokupnom uzorku manja od tog iznosa, dok je druga polovina veća. Isti pokazatelj za Ripple iznosi 0,1922 \$.

**Tablica 9: Deskriptivna analiza nezavisnih varijabli**

	Hashrate ETH	Google trend etheruma	Google trend ripple	Broj trans. Etheruma po danu	Broj trans. Ripplea po danu	Cijena zlata USD/OZ
N Valid	156	156	156	156	156	150
Missing	0	0	0	0	0	6
Mean	105401,0600	22,65	13,27	344594,88	677738,42	1259,97
Median	63906,7341	13,50	11,00	248692,00	622756,50	1258,45
Std. Deviation	109607,27063	19,340	14,549	324290,671	260620,654	55,742
Minimum	550,71	1	1	9875	91402	1094
Maximum	292146,49	100	100	1271577	1347170	1354

Izvor: Izrada autora

Tablica 9 prikazuje deskriptivnu statistiku šest nezavisnih varijabli u ovom istraživanju. Osim cijene zlata kod koje nedostaje 6 podataka, sve ostale uzorke čini 156 podataka. Za varijablu hashrate Ethereum imamo visoku standardnu devijaciju, tj. prosječno odstupanje od prosjeka, što je i očekivano s obzirom na vremenski period i veliki rast te varijable. Prosječna vrijednost iznosi 105401,06, najniža 550,71, a najviša 292146,49. Medijan iznosi 63906,7341, a interpretira se na način da polovina podataka iz uzorka ima manju vrijednost od tog iznosa, dok polovina ima veću vrijednost. Za obe varijable s podacima o google trendu minimalni iznosi je 1, a maksimalni 100, s obzirom da se radi o skali podataka. Standardna devijacija i kod jedne i druge varijable nije izrazito visoka. Dvije varijable koje sadrže broj transakcije ove dvije kriptovalute imaju visoku standardnu devijaciju od 324290,671 za Ethereum, odnosno 260620,654 za Ripple, što govori o velikim razlikama u podacima kroz vrijeme. Podaci o prosječnom, najnižem i najvišem broju transakcija vidljivi su u tablici. Kod cijene zlata standardna devijacija iznosi 55,742, te govori malom prosječnom odstupanju od prosjeka.

#### 4.3.3. Korelacija varijabli

Provjera korelacija među varijablama provedena je posebno za oba modela, prikazom korelacije između zavisne i nezavisnih varijabli, te prikazom velike tablice korelacija svih varijabli koje se pojavljuju u našem istraživanju. Povezanost između varijabli je utvrđena je primjenom Pearson's Coefficient Correlation (Pearsonov koeficijent korelacije) uz sljedeća pravila:

- Veoma snažna pozitivna/negativna povezanost (od 0,90 do 1,0 i od -0,90 do -1,0).
- Snažna pozitivna/negativna povezanost (od 0,70 do 0,90 i od -0,70 do -0,90).
- Umjerena pozitivna/negativna povezanost (od 0,50 do 0,70 i od -0,50 do -0,70).
- Slaba pozitivna/negativna povezanost (od 0,30 do 0,50 i od -0,30 do -0,50).
- Neznatna pozitivna/negativna povezanost (od 0,00 do 0,30 i od -0,00 do -0,30).

**Tablica 10: Korelacija svih varijabli u istraživanju**

		cijena Ethereuma \$	cijena Ripplea \$	hashrate ETH	Google trend ethereum	Google trend ripple	transakcijski obujam ethereum (br.trans. po danu)	transakcijski obujam ripplea (br. trans. po danu)	cijena zlata USD/OZ
cijena Ethereum \$	Pearson Correlation	1	,867**	,715**	-,225*	,461**	,895**	,395**	,420**
	Sig. (2-tailed)		,000	,000	,005	,000	,000	,000	,000
	N	156	156	156	156	156	156	156	150
cijena Ripplea \$	Pearson Correlation	,867**	1	,616**	-,154	,695**	,846**	,376**	,324**
	Sig. (2-tailed)	,000		,000	,056	,000	,000	,000	,000
	N	156	156	156	156	156	156	156	150
hashrate ETH	Pearson Correlation	,715**	,616**	1	-,501**	,049	,875**	-,010	,135
	Sig. (2-tailed)	,000	,000		,000	,541	,000	,900	,098
	N	156	156	156	156	156	156	156	150
Google trend ethereum	Pearson Correlation	-,225*	-,154	-,501**	1	,458**	-,365**	,021	,196
	Sig. (2-tailed)	,005	,056	,000		,000	,000	,799	,016
	N	156	156	156	156	156	156	156	150
Google trend ripple	Pearson Correlation	,461**	,695**	,049	,458**	1	,381**	,371**	,224**
	Sig. (2-tailed)	,000	,000	,541	,000		,000	,000	,006
	N	156	156	156	156	156	156	156	150
transakcijski obujam ethereum (br.trans. po danu)	Pearson Correlation	,895**	,846**	,875**	-,365**	,381**	1	,256**	,287**
	Sig. (2-tailed)	,000	,000	,000	,000	,000		,001	,000
	N	156	156	156	156	156	156	156	150
transakcijski obujam ripplea (br. trans. po danu)	Pearson Correlation	,395**	,376**	-,010	,021	,371**	,256**	1	,168
	Sig. (2-tailed)	,000	,000	,900	,799	,000	,001		,040
	N	156	156	156	156	156	156	156	150
cijena zlata USD/OZ	Pearson Correlation	,420**	,324**	,135	,196	,224**	,287**	,168	1
	Sig. (2-tailed)	,000	,000	,098	,016	,006	,000	,040	
	N	150	150	150	150	150	150	150	150

\*\* . Correlation is significant at the 0.01 level (2-tailed).

\* . Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora

**Tablica 11: Korelacija varijabli MODELA 1**

		cijena Ethereuma \$	hashrate ETH	Google trend ethereum	transakcijski obujam ethereum (br.trans. po danu)	cijena zlata USD/OZ
cijena Ethereum \$	Pearson Correlation	1	,715**	-,225**	,895**	,420**
	Sig. (2-tailed)		,000	,005	,000	,000
	N	156	156	156	156	150
hashrate ETH	Pearson Correlation	,715**	1	-,501**	,875**	,135
	Sig. (2-tailed)	,000		,000	,000	,098
	N	156	156	156	156	150
Google trend ethereum	Pearson Correlation	-,225**	-,501**	1	-,365**	,196*
	Sig. (2-tailed)	,005	,000		,000	,016
	N	156	156	156	156	150
transakcijski obujam ethereum (br.trans. po danu)	Pearson Correlation	,895**	,875**	-,365**	1	,287**
	Sig. (2-tailed)	,000	,000	,000		,000
	N	156	156	156	156	150
cijena zlata USD/OZ	Pearson Correlation	,420**	,135	,196*	,287**	1
	Sig. (2-tailed)	,000	,098	,016	,000	
	N	150	150	150	150	150

\*\* . Correlation is significant at the 0.01 level (2-tailed).

\* . Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora

**Tablica 12: Korelacija varijabli MODELA 2**

		cijena Ripplea \$	Google trend ripple	transakcijski obujam ripple (br. trans. po danu)	cijena zlata USD/OZ
cijena Ripplea \$	Pearson Correlation	1	,695**	,376**	,324**
	Sig. (2-tailed)		,000	,000	,000
	N	156	156	156	150
Google trend ripple	Pearson Correlation	,695**	1	,371**	,224**
	Sig. (2-tailed)	,000		,000	,006
	N	156	156	156	150
transakcijski obujam ripple (br. trans. po danu)	Pearson Correlation	,376**	,371**	1	,168*
	Sig. (2-tailed)	,000	,000		,040
	N	156	156	156	150
cijena zlata USD/OZ	Pearson Correlation	,324**	,224**	,168*	1
	Sig. (2-tailed)	,000	,006	,040	
	N	150	150	150	150

\*\* . Correlation is significant at the 0.01 level (2-tailed).

\* . Correlation is significant at the 0.05 level (2-tailed).

Izvor: Izrada autora

Podaci iz Tablice 10 prikazuje povezanost svih varijabli koje su uključene u ovo istraživanje. S obzirom na postavljena istraživačka pitanja, u Tablici 11 i Tablici 12 posebno su postavljene

korelacije između zavisne i nezavisnih varijabli oba modela istraživanja. No, svejedno vrijedi naglasiti, a vidljivo je iz Tablice 10, da postoji statistički značajna korelacija, praktično dovoljno visoka te pozitivna korelacija između dvije zavisne varijable cijene Ethereum i cijene Ripplea. Iz toga možemo zaključiti kako cijena jedne kriptovalute značajno utječe na drugu.

Tablica 11 prikazuje korelaciju između *cijene Ethereum* kao zavisne varijable, te četiri nezavisne varijable u MODELU 1. Poštujući prethodno navedena pravila, vidljivo je da zavisna varijabla ima pozitivnu snažnu povezanost s varijablama *hashrate* (0,715) i *transakcijski obujam Ethereum* (0,895), slabu pozitivnu povezanost s *cijenom zlata* (0,420), te neznačajnu korelaciju s *google trendom Ethereum* (-0,225). U konačnom obliku MODELA 1, google trend Ethereum biti će izbačena varijabla koja nema statistički utjecaj na zavisnu.

Tablica 12 prikazuje korelaciju između *cijene Ripplea* kao zavisne varijable, te tri nezavisne varijable u MODELU 2. Postoji pozitivna povezanost sve tri nezavisne varijable sa zavisnom. Između varijable *google trend Ripplea* i zavisne postoji umjerena pozitivna korelacija (0,695), dok između zavisne varijable i *transakcijskog obujma Ripplea* (0,376), odnosno *cijene zlata* (0,324) postoji slaba pozitivna, no ipak praktično dovoljno velika korelacija.

#### 4.4. Regresijska analiza

Nakon utvrđenih korelacija između korištenih varijabli, te provedene deskriptivne analize parametara ovog istraživanja, slijedi proces testiranja ekonomskih modela. Korišten je proces višestruke regresijske analize, provedene u programskom paketu SPSS. Osim višestruke regresije, poznajemo i jednostavnu regresijsku analizu, s razlikom što kod višestruke analize postoji veći broj nezavisnih, tj regresorskih varijabli. S obzirom da se podrazumijeva linearan odnos između zavisne i nezavisnih varijabli, radi se o višestrukoj linearnoj regresijskoj analizi. Rozga (2009) navodi da višestruka regresijska analiza predstavlja ispitivanje ovisnosti jedne zavisne (regresand) varijable o dvije ili više nezavisnih (regresorskih) varijabli s ciljem da se utvrdi analitički izraz takve povezanosti. Isti autor navodi pretpostavke višestrukog linearnog modela regresijske analize:

1. Model populacije osnovnog skupa je linearan.
2. Očekivana vrijednost grešaka relacije je jednaka nuli, odnosno očekivana (prosječna) vrijednost zavisne varijable za zadane vrijednosti nezavisnih varijabli je linearna funkcija.
3. Varijanca grešaka relacije je konstantna, odnosno varijanca zavisne varijable je konstanta.

4. Slučajne varijable  $\varepsilon_i$  i  $\varepsilon_j$  su nekorelirane, odnosno  $y_i$  i  $y_j$  su nekorelirane, gdje vrijedi  $i \neq j$ .
5. Greška relacije  $\varepsilon_i$  su normalno distribuirane slučajne varijable, odnosno zavisna varijabla je normalno distribuirana slučajna varijabla.
6. Regresorske varijable su nekorelirane i niti jedna nije konstanta, odnosno ne postoji egzaktna linearna povezanost između dvije ili više varijabli.

Regresijska analiza provest će se kroz dva modela, s obzirom na dvije zavisne varijable za koje se istražuje utjecaj determinanti. MODEL 1 kod kojeg se kod postavljanja istraživačkih pitanja odredilo 4 glavne determinante, u konačnom obliku ima 3 nezavisne varijable, jednako kao i MODEL 2. Korištena je Backward metoda programskog paketa SPSS kako bi se dijagnosticirale, te iz modela izbacile varijable koje nisu statistički značajne.

#### 4.4.1. MODEL 1

U nastavku će biti provedena regresijska analiza i ocjena regresijskih parametara u MODELU 1. Početni oblik modela  $ETH = \beta_0 + \beta_1 HASH + \beta_2 GOLD + \beta_3 TPDE + \beta_4 GTE$ , sadrži četiri zavisne varijable te su rezultati regresijskih parametara vidljivi u prvom redu tablica, dok drugi red čine rezultati za konačan oblik s tri nezavisne varijable nakon izbacivanja statistički neznačajne varijable *google trend Ethereuma*. Konačan oblik modela glasi  $ETH = \beta_0 + \beta_1 HASH + \beta_2 GOLD + \beta_3 TPDE$ .

**Tablica 13: Osnovni podaci o MODELU 1**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,917 <sup>a</sup>	,841	,836	112,03513195
2	,916 <sup>b</sup>	,840	,837	111,86592494
a. Predictors: (Constant), cijena zlata USD/OZ, hashrate ETH, Google trend ethereuma, transakcijski obujam ethereuma (br.trans. po danu)				
b. Predictors: (Constant), cijena zlata USD/OZ, hashrate ETH, transakcijski obujam ethereuma (br.trans. po danu)				

Izvor: Izrada autora

Koeficijent multiple determinacije ( $R^2$ ) početnog oblika modela iznosi 0,841, dok nakon izbacivanja varijable *google trend Ethereuma* iznosi 0,840. Govori nam da je 84,1 % zbroja kvadrata ukupnih odstupanja zavisne varijable od svoje aritmetičke sredine protumačeno ovim modelom. Vidimo da se nakon izbacivanja statistički neznačajne varijable gotovo da i nije smanjio, te i dalje visoka vrijednost označava dobru reprezentativnost modela. Korigirani koeficijent determinacije ( $\hat{R}^2$ ) iznosi 0,837 za konačni oblik modela.



**Tablica 14: Tablica ANOVA (MODEL 1)**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	9591415,831	4	2397853,958	191,036	,000 <sup>a</sup>
	Residual	1820021,265	145	12551,871		
	Total	11411437,095	149			
2	Regression	9584395,261	3	3194798,420	255,298	,000 <sup>b</sup>
	Residual	1827041,834	146	12513,985		
	Total	11411437,095	149			
a. Predictors: (Constant), cijena zlata USD/OZ, hashrate ETH, Google trend ethereuma, transakcijski obujam ethereuma (br.trans. po danu)						
b. Predictors: (Constant), cijena zlata USD/OZ, hashrate ETH, transakcijski obujam ethereuma (br.trans. po danu)						

Izvor: Izrada autora

Tablica 14 nam daje podatke o graničnoj razini signifikantnosti, a iznosi  $\alpha \approx 0$ , otkriva da je regresijski model statistički značajan pri razini signifikantnosti manjoj od 1%. Također iz tablice se mogu vidjeti protumačena, neprotumačena i ukupna odstupanja ocijenjenog modela.

**Tablica 15: Regresijski MODEL 1**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
		B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1	(Constant)	-848,868	227,755		-3,727	,000	-1299,016	-398,720		
	hashrate ETH	-,001	,000	-,293	-3,588	,000	-,001	,000	,165	6,059
	Google trend ethereuma	,429	,574	,030	,748	,456	-,705	1,563	,669	1,495
	transakcijski obujam ethereuma (br.trans. po danu)	,001	,000	1,127	14,042	,000	,001	,001	,171	5,852
	cijena zlata USD/OZ	,649	,186	,131	3,485	,001	,281	1,017	,781	1,280
2	(Constant)	-882,787	222,856		-3,961	,000	-1323,228	-442,346		
	hashrate ETH	-,001	,000	-,312	-4,036	,000	-,001	,000	,183	5,455
	transakcijski obujam ethereuma (br.trans. po danu)	,001	,000	1,130	14,123	,000	,001	,001	,171	5,835
	cijena zlata USD/OZ	,687	,179	,138	3,839	,000	,333	1,041	,844	1,185

a. Dependent Variable: cijena Ethereuma \$

Izvor: Izrada autora

Iz gornje tablice vidimo dva oblika modela, prvi s četiri nezavisne varijable, te konačni nakon izbačene varijable google trend Ethereuma. Razlog izbacivanja je signifikantnost od 0,456, što nije statistički značajna varijabla. Tablica 16 prikazuje nam izbačenu varijablu.

**Tablica 16: Izbačena varijabla MODELA 1**

Model	Beta In	t	Sig.	Partial Correlation	Collinearity Statistics		
					Tolerance	VIF	Minimum Tolerance
2 Google trend ethereuma	,030 <sup>a</sup>	,748	,456	,062	,669	1,495	,165
a. Predictors in the Model: (Constant), cijena zlata USD/OZ, hashrate ETH, transakcijski obujam ethereuma (br.trans. po danu)							

Izvor: Izrada autora

Ostale tri nezavisne varijable (*hashrate*, *transakcijski obujam Ethereuma* i *cijena zlata*) statistički su značajni, te ulaze u model, koji sada možemo zapisati kao:

$$\text{ETH} = -882,787 - 0,001\text{HASH} + 0,687\text{GOLD} + 0,001\text{TPDE}.$$

Hashrate ima negativan utjecaj na zavisnu varijablu, dok cijena zlata i transakcijski obujam pozitivno utječu na cijenu Ethereuma. Detaljna analiza rezultata slijedi u nastavku rada.

Vrijedi napomenuti da su uočena dva zapažanja koja značajno odstupaju od modela, i to zapažanja pod rednim brojevima 111 i 155. S obzirom da se rezultati nisu značajnije promijenili izbacivanjem ta dva slučaja iz analize, neće se posebno prikazivati tablice regresijske analize bez ta dva netipična zapažanja. Prikazana su u donjoj tablici.

**Tablica 17: Netipična zapažanja**

Case Number	Std. Residual	cijena Ethereuma \$	Predicted Value	Residual
111	3,489	944,21000	553,9192733	390,29
155	-3,065	109,50000	452,4048875	-342,90488745

Izvor: Izrada autora

#### 4.4.2. MODEL 2

Slijedi regresijska analiza MODELA 2, koji sadrži tri nezavisne varijable, a početni postavljeni oblik glasi  $\text{RPL} = \beta_0 + \beta_1\text{GOLD} + \beta_2\text{TPDR} + \beta_3\text{GTR}$ .

**Tablica 18: Osnovni podaci o MODELU 2**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,685 <sup>a</sup>	,469	,458	,29740642

a. Predictors: (Constant), cijena zlata USD/OZ, transakcijski obujam ripplea (br. trans. po danu), Google trend ripple

Izvor: Izrada autora

Koeficijent multiple determinacije (R<sup>2</sup>) modela iznosi 0,469, što nam govori da je 46,9 % zbroja kvadrata ukupnih odstupanja zavisne varijable od svoje aritmetičke sredine protumačeno ovim modelom. Statistički bi bilo bolje da je taj iznos veći, no i sad je praktično dovoljno velik za analizu. Korigirani koeficijent determinacije ( $\hat{R}^2$ ) iznosi 0,458.

**Tablica 19: Tablica ANOVA (MODEL 2)**

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	11,422	3	3,807	43,043	,000 <sup>a</sup>
Residual	12,914	146	,088		
Total	24,335	149			

a. Predictors: (Constant), cijena zlata USD/OZ, transakcijski obujam ripplea (br. trans. po danu), Google trend ripple

Izvor: Izrada autora

Iz tablice 19 vidljivo je da je granična razina signifikantnosti  $\alpha^* \approx 0$ , te se zaključuje da je regresijski model statistički značajan pri razini signifikantnosti manjoj od 1%. Također iz tablice se mogu vidjeti protumačena, neprotumačena i ukupna odstupanja ocijenjenog modela.

**Tablica 20: Regresijski MODEL 2**

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1 (Constant)	-1,669	,561		-2,976	,003	-2,777	-,561		
Google trend ripple transakcijski obujam ripplea (br. trans. po danu)	,017	,002	,567	8,784	,000	,013	,021	,872	1,147
cijena zlata USD/OZ	2,107E-007	,000	,133	2,083	,039	,000	,000	,892	1,121
	,001	,000	,175	2,812	,006	,000	,002	,939	1,065
a. Dependent Variable: cijena Ripplea \$									

Izvor: Izrada autora

U MODELU 2 sve tri početno postavljene nezavisne varijable pokazale su se kao statistički značajne, s obzirom da kod svake signifikantnost iznosi  $<0,05$ , te niti jedna od njih nije izbačena iz

početnog oblika modela, što je bio slučaj kod MODELA 1. Za varijablu *google trend Ripplea* signifikantnost iznosi  $0,000 < 0,05$ , za *transakcijski obujam Ripplea* iznosi  $0,039 < 0,05$ , dok za *cijenu zlata* iznosi  $0,006 < 0,05$ . Sve tri nezavisne varijable utječu blago pozitivno na zavisnu varijablu, a detaljno objašnjenje rezultata slijedu u dijelu Interpretacija rezultata.

#### 4.5. Interpretacija rezultata

Na početku rada postavljeno je sedam istraživačkih pitanja na koja smo nastojali dati odgovor, te je u svrhu toga provedena višestruka regresijska analiza te korelacija varijabli unesenih u istraživanje. Postavljena su sljedeća pitanja:

- Kako hashrate utječe na cijenu Ethereum?
- Kako cijena zlata utječe na cijenu Ethereum?
- Kako cijena zlata utječe na cijenu Ripplea?
- Ima li popularnost dobivena podacima s google trenda utjecaj na cijenu Ethereum?
- Kako popularnost utječe na cijenu Ripplea?
- Kako transakcijski obujam utječe na cijenu Ethereum?
- Kako transakcijski obujam utječe na cijenu Ripplea?

S obzirom na činjenicu da su gotova sva istraživanja na ovu temu do sada rađena za Bitcoin, kao najutjecajnicu kriptovalutu koja je postavljena za zavisnu varijablu, teško smo mogli pretpostaviti utjecaje ovih determinanti na dvije kriptovalute u ovom istraživanju, Ethereum i Ripple. Razlog tomu su velike razlike u većini parametara između Bitcoina kao najveće i najpopularnije valute s dvije navedene u ovom radu. Ipak, vodeći se prijašnjih istraživanja za Bitcoin, može se reći da prevladavaju rezultati o pozitivnom utjecaju transakcijskog obujma i hashratea na cijenu kriptovalute, negativan utjecaj google trenda, dok za cijenu zlata nije moguće reći s obzirom da niti jedan utjecaj ne dominira u većini istraživanja. Razlog tomu, ali i odstupanju dobivenih rezultata u ovom istraživanju od očekivanih leži u vremenskom periodu istraživanja, te činjenici da se sve unesene varijable mijenjaju praktički iz sata u sat, te je za očekivati da rezultati za dnevna, tjedna ili mjesečna istraživanja neće biti jednaki.

Kod pribavljanja uzoraka za ovo istraživanje u obzir su uzeti tjedni podaci, konkretno cijene zavisnih varijabli te nezavisne varijable svakog petka u periodu od siječnja 2016. godine do prosinca 2018. godine. Dobiveni su sljedeći rezultati po kojima će se dati odgovori na postavljena

istraživačka pitanja. Hashrate se pokazao kao statistički značajna varijabla u MODELU 1, sa razinom signifikantnosti od  $0,000 < 0,05$ . Dobiveni koeficijent B iznosi  $-0,001$ , te označava vrlo blagi negativni utjecaj hashratea na cijenu Ethereum. Konkretno, povećanje hashratea za 1 jedinicu (hash po sekundi) dovesti će do smanjena cijene Ethereum od  $0,001$  \$. Cijena zlata također se pokazala kao statistički značajna varijabla s razinom signifikantnosti od  $0,001$ . Koeficijent B od  $0,649$  pokazuje da determinanta cijena zlata ima pozitivan utjecaj na cijenu Ethereum, tj. kada se cijena jedne unce zlata poveća za  $1$  \$, cijena Ethereum narasti će za  $0,649$  \$. U MODELU 2 varijabla cijena zlata statistički je značajna s razinom signifikantnosti od  $0,006 < 0,05$ , te također pozitivno utječe na cijenu Ripplea s koeficijentom B od  $0,001$ . Povećanje cijene jedne unce zlata za  $1$  \$ utjecat će na povećanje cijene Ripplea za  $0,001$  \$. Jedina nezavisna varijabla kod koje nismo uočili statističku značajnost s razinom signifikantnosti od  $0,456 > 0,05$  je google trend Ethereum. S obzirom na to, odgovor na četvrto istraživačko pitanje glasi da google trend nema utjecaj na cijenu Ethereum, te tu varijablu izbacujemo iz konačnog modela. U MODELU 2 uočena je statistička značajnost determinante google trend Ripplea, te zaključujemo da on blago pozitivno utječe na cijenu Ripplea. Koeficijent B od  $0,017$  govori nam da se cijena Ripplea poveća za  $0,017$  \$ kada se pretraživanja za pojmom Ripple na googleu povećaju za jedan poen. Nezavisna varijabla transakcijski obujam Ethereum u MODELU 1 ima razinu signifikantnosti od  $0,00$  statistički je značajna varijabla, te zaključujemo da povećanje obujma transakcija za jednu transakciju po danu utječe na povećanje cijene za  $0,001$  \$. Ukoliko broj transakcija izrazimo u tisućama, rast broja transakcija za jednu tisuću uzrokuje rast cijene Ethereum za  $1$  \$. Determinanta transakcijski obujam Ripplea statistički je značajna varijabla u MODELU 2 s razinom signifikantnost od  $0,039$ . Koeficijent B iznosi izrazito niskih  $0,0000002107$ . Kada broj dnevnih transakcija izrazimo u tisućama dolazimo do zaključka da povećanje broja transakcija Ripplea za tisuću uzrokuje povećanje cijene Ripplea za  $0,0002107$  \$.

## 5. ZAKLJUČAK

Početkom stoljeća razvila se potreba za elektronskim novcem, što je postepeno dovelo i do razvitka kriptovaluta. Prva necentralizirana kriptovaluta Bitcoin razvijena je 2009. godine, a do danas ih je razvijeno čak 2194. Tema ovog rada bila je analiza pojedinih determinanti koje utječu na cijenu Ethereum kao druge, te Ripplea kao treće vodeće kriptovalute s obzirom na tržišnu kapitalizaciju. Bitcoin kao uvjerljivo vodeća kriptovaluta nije bila jedna od zavisnih varijabli u ovom istraživanju upravo zbog svoje popularnosti i činjenice da postoje brojna istraživanja na tu temu, dok su ostale kriptovalute zanemarene od drugih autora.

Teorijski dio ovog rada služi kao dobra podloga za razumjevanje pojma kriptovaluta općenito, kako bi uopće mogli razmišljati o formiranju cijene te vrste valute i utjecaju na nju. Pregled literature i prijašnjih istraživanja uglavnom na temu Bitcoina pomogao je u odabiru nezavisnih varijabli ovog istraživanja, čiji će se utjecaj statistički ispitati. Empirijski dio uzeo je u obzir cijene Ethereuma u jednom, odnosno cijene Rippla u drugom modelu istraživanja, te je istražen utjecaj odabranih determinanti na zavisne varijable kako bi se pokušao dati odgovor na postavljena istraživačka pitanja. Regresijska analiza provedena pomoću programskog paketa SPSS pokazala je čak pet od šest nezavisnih varijabli statistički značajnim. To je dalo mogućnost dati odgovor na šest od sedam postavljenih istraživačkih pitanja.

Zaključuje se da determinanta google trend Ethereuma jedina nije pokazala statističku značajnost te nije uzeta u obzir prilikom odgovora na istraživačka pitanja. Hashratea jedina je varijabla s negativnim utjecajem na cijenu Ethereuma, dok su cijena zlata i transakcijski obujam pokazali pozitivan utjecaj na cijenu Ethereuma. Kod drugog modela sa cijenom Ripplea kao zavisnom varijablom sve tri determinante (google trend Ripplea, transakcijski obujam Ripplea i cijena zlata) pokazale su se statistički značajne, te imaju pozitivan utjecaj na cijenu. Kod oba modela valja napomenuti da je utjecaj jako mal te ne mijenja značajno cijenu, no ipak je statistički značajan, te ove determinante uz ostale neuvrštene u istraživanje oblikuju cijenu kriptovaluta iz dana u dan.

Kako je i ranije navedeno, kod ovakvih varijabli koje su vrlo fluktuativne kao što su cijene kriptovaluta teško možemo govoriti o očekivanjima, s obzirom da se cijene praktički mijenjaju iz sata u sat, te velik utjecaj na rezultate ima odabrani vremenski period istraživanja. Također velika je razlika u podacima o Bitcoinu s kojim smo u gornjem dijelu rada pokušali usporediti očekivane rezultate i dvije kriptovalute iz ovog istraživanja.

## 6. LITERATURA

1. Aljinović, Z., Marasović, B. (2012). "*Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*", Ekonomski fakultet u Splitu, Split, 2012.
2. Babić, R., Krajnović, A., Radman Peša, A. (2011): "*Dosezi elektroničke trgovine u Hrvatskoj i svijetu*", Oeconomica Jadertina, 2011. (48-68), dostupno na: <http://hrcak.srce.hr/75179>
3. Baur, D. G., Dimpflb, T., Kuckc, K. (2017.): *Bitcoin, gold and the US dollar – A replication and extension*, Finance research letters, 2017., dostupno na: [https://www.bedicon.org/wp-content/uploads/2018/01/finance\\_topic4\\_source2.pdf](https://www.bedicon.org/wp-content/uploads/2018/01/finance_topic4_source2.pdf)
4. Bitconnect: *How is the price of cryptocurrency defined?*, preuzeto 28.8.2018., dostupno na: <https://bitconnect.co/bitcoin-information/10/how-is-the-price-of-cryptocurrency-defined>
5. Bouoiyour, J., Selmi, R. (2014.): *What bitcoin looks like?*, 2014., dostupno na: <http://mpa.ub.uni-muenchen.de/58091/>
6. Buterin, D., Ribarić, E., Savić, S. (2015.): "*Bitcoin - nova globalna valuta, investicijska prilika ili nešto treće?*", Zbornik Veleučilišta u Rijeci, str. 145., Rijeka 2015., dostupno na: [https://www.veleri.hr/files/datoteke/knjige/digi/2015\\_04\\_15\\_Veleuciliste%20Zbornik.pdf](https://www.veleri.hr/files/datoteke/knjige/digi/2015_04_15_Veleuciliste%20Zbornik.pdf)
7. Cata, J. (2018): "*Everything to know about Ripple – part : How Ripple works*", A Medium corporatium, US, dostupno na: <https://medium.com/@jcata018/everything-to-know-about-ripple-part-1-how-ripple-works-f7404aa4a8d1>
8. Chaum, D. (1983.): *Blind signatures for untraceable payments*, University of California, Santa Barbara CA, 1983
9. Chaum, L. D. (1983.): *Blind signatures for untraceable payments*, University of California, Santa Barbara CA, 1983., dostupno na: <http://www.hit.bme.hu/~buttyan/courses/BMEVIHIM219/2009/Chaum.BlindSigForPayment.1982.PDF>
10. Ciaian, P., Rajcaniova, M., Kancs (2015.): *The economics of BitCoin price formation*, Taylor & Francis online, 2015., dostupno na: <https://www.tandfonline.com/doi/full/10.1080/00036846.2015.1109038>
11. Crosby, M., Pattanayak, P., Verma, S., Kalyanaraman, V. (2016): "*BlockChain technology: Beyond Bitcoin*", Applied inovation review, Issue no 2, 2016., dostupno na: <https://j2-capital.com/wp-content/uploads/2017/11/AIR-2016-Blockchain.pdf>
12. Cunjak Mataković, I., Mataković, H. (2018.): "*Kriptovalute-sofisticirani kodovi*

- manipulacije*", International Journal of Digital Technology & Economy, 2018., dostupno na: [https://hrcak.srce.hr/index.php?show=clanak&id\\_clanak\\_jezik=315456](https://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=315456)
13. Demian Lerner, S. (2013): "The Well Deserved Fortune of Satoshi Nakamoto, Bitcoin Creator, Visionary and Genius.", Bitsblog, 2013., dostupno na: <https://bitslog.wordpress.com/2013/04/17/the-well-deserved-fortune-of-satoshi-nakamoto/>
  14. Dyhrberg, A. H. (2015.): *Bitcoin, Gold and the Dollar – a GARCH Volatility Analysis*, University College Dublin. School of Economics, 2015., dostupno na: [http://irserver.ucd.ie/bitstream/handle/10197/7168/WP15\\_20.pdf?sequence=1](http://irserver.ucd.ie/bitstream/handle/10197/7168/WP15_20.pdf?sequence=1)
  15. Franco, P. (2015): *"Understanding Bitcoin: Cryptography, engineering, and economics"*, TJ International Ltd, Padstow, Cornwall, UK, 2015., dostupno na: [https://the-eye.eu/public/Books/qt.vidyagam.es/library/humble-bitcoin-bundle/Understanding%20Bitcoin\\_%20Cryptography%2C%20Engineering%20and%20Economics/Understanding%20Bitcoin\\_%20Cryptography%2C%20Engineering%20and%20Economics%20-%20Pedro%20Franco.pdf](https://the-eye.eu/public/Books/qt.vidyagam.es/library/humble-bitcoin-bundle/Understanding%20Bitcoin_%20Cryptography%2C%20Engineering%20and%20Economics/Understanding%20Bitcoin_%20Cryptography%2C%20Engineering%20and%20Economics%20-%20Pedro%20Franco.pdf)
  16. Garcia, D., Tessone, C. J., Mavrodiev, P., Perony, N., (2014.): *The digital traces of bubbles: feedback cycles between socio-economic signals in the Bitcoin economy*, The royal society publishing, 2014., dostupno na: <http://rsif.royalsocietypublishing.org/content/11/99/20140623>
  17. Greenberg, A. (2011.): *Crypto Currency*, Forbes.com, 2011., dostupno na <https://www.forbes.com/forbes/2011/0509/technology-psilocybin-bitcoins-gavin-andresen-crypto-currency.html#11c8caf4353e>
  18. Hamdi, H. (2007): *"Problemi razvoja elektroničkog novca"*, Financijska teorija i praksa, no. 3, 2007.
  19. Hankins, A. (2018.): *Bitcoin begins the week with a stumble; SEC announces adviser for digital assets*, Market Watch, 2018., dostupno na: <https://www.marketwatch.com/story/bitcoin-begins-the-week-on-a-sour-note-2018-06-04>
  20. Hayes, A. (2015.): *Cryptocurrency value formation: An empirical analysis leading to a cost of production model for valuing bitcoin*, MCIS, 2015., dostupno na [https://www.researchgate.net/profile/Adam\\_Hayes2/publication/303094852\\_Cryptocurrency\\_Value\\_Formation\\_An\\_empirical\\_study\\_leading\\_to\\_a\\_cost\\_of\\_production\\_model\\_for\\_valuing\\_Bitcoin/links/59db8d61aca2724fc9063637/Cryptocurrency-Value-Formation-An-empirical-study-leading-to-a-cost-of-production-model-for-valuing-Bitcoin.pdf](https://www.researchgate.net/profile/Adam_Hayes2/publication/303094852_Cryptocurrency_Value_Formation_An_empirical_study_leading_to_a_cost_of_production_model_for_valuing_Bitcoin/links/59db8d61aca2724fc9063637/Cryptocurrency-Value-Formation-An-empirical-study-leading-to-a-cost-of-production-model-for-valuing-Bitcoin.pdf)
  21. Hileman, G., Rauch, M. (2017): *"Global cryptocurrency benchmarking study"*,



- University of Cambridge, 2017., dostupno na: <https://cdn.crowdfundinsider.com/wp-content/uploads/2017/04/Global-Cryptocurrency-Benchmarking-Study.pdf>
22. Hozjan, D. (2017.): "*Blockchain*", Diplomski rad, Sveučilište u Zagrebu, 2017., dostupno na: <https://zir.nsk.hr/islandora/object/pmf%3A779>
  23. <http://www.ethdocs.org/en/latest/>
  24. <https://admiralmarkets.com.hr/education/articles/cryptocurrencies/sto-je-ripple>
  25. <https://blog.bitmex.com/the-ripple-story/>
  26. <https://coinmarketcap.com/>
  27. <https://fimaplus.com/kripto-vodic/>
  28. <https://povijest.hr/>
  29. <https://whatis.techtarget.com>
  30. <https://www.bitcoin-hrvatska.com/>
  31. <https://www.blockchain.com/>
  32. <https://www.coinsutra.com/>
  33. <https://www.crobitcoin.com/>
  34. Jenssen, B. T., (2014.): *Why Bitcoins Have Value, and Why Governments Are Sceptical*, University of Oslo, 2014., dostupno na: <https://www.duo.uio.no/handle/10852/40966>
  35. Kapoor, R. (2016): "*Regulating The Bitcoin Ecosystem* ", Master thesis, Delft University of Technology, 2016., dostupno na: <https://repository.tudelft.nl/islandora/object/uuid%3A114d5e17-8389-4f1c-87e2-b175bb3830e1>
  36. Kaselj, M. (2015): "*Bitcoin*", Diplomski rad. Sveučilište Josipa Jurja Strossmayera u Osijeku, 2015., dostupno na: <https://zir.nsk.hr/islandora/object/mathos:24>
  37. Kavvadias, G., (2017.): *What drives the value of cryptocurrencies? A time series analysis of bitcoin*, Tilburg University, 2017., dostupno na: <http://arno.uvt.nl/show.cgi?fid=145139>
  38. Kristoufek, L. (2014.): *What are the main drivers of the Bitcoin price? Evidence from wavelet coherence analysis*, 2014., dostupno na: <https://arxiv.org/pdf/1406.0268.pdf>
  39. Letra, I. (2016): "*What drives cryptocurrency value? A volatility and predictability analysis*", Lisbon school of economics & management, 2016., dostupno na: <https://www.repository.utl.pt/bitstream/10400.5/12556/1/DM-IJSL-2016.pdf>
  40. Nakamoto, S. (2008.): "*Bitcoin: A Peer-to-Peer Electronic System*", 2008., dostupno na: <https://fimaplus.com/wp-content/uploads/2018/03/Bitcoin-Whitepaper.pdf>
  41. Nakamoto, S. (2009): Bitcoin v0.1 released, Satoshi Nakamoto Institute, 2009., dostupno na: <https://satoshi.nakamotoinstitute.org/emails/cryptography/17/#selection-37.3-47.1>

42. Novak, I. (2008): *"Analiza inozemnog duga RH modelom višestruke linearne regresije"*, Zbornik Ekonomskog fakulteta u Zagrebu, godina 6, 2008., dostupno na: <https://hrcak.srce.hr/30952>
43. Palombizio, E., Morris, I. (2012.): *Forecasting Exchange Rates using Leading Economic Indicators*, Open Access Scientific Reports, 2012., dostupno na: <https://www.omicsonline.org/scientific-reports/2168-9458-SR-402.pdf>
44. Peck, E. M. (2012.): *Bitcoin: The Cryptoanarchists' Answer to Cash*, IEEE Spectrum, 2012., dostupno na <https://spectrum.ieee.org/computing/software/bitcoin-the-cryptoanarchists-answer-to-cash>
45. Pleša Puljić, N., Celić M., Puljić M. (2017.): *"Povijest i budućnost prodavaonica"*, Praktični menadžment, Vol. VIII., br. 1., str. 38-47, 2017.
46. Polasik, M., Piotrowska, I. A., Wisniewski, P. T., Kotkowski, R., Lightfoot, G. (2014.): *Price Fluctuations and the Use of Bitcoin: An Empirical Inquiry*, 2014., dostupno na: [https://www.ecb.europa.eu/pub/conferences/shared/pdf/retpaym\\_150604/polasik\\_paper.pdf](https://www.ecb.europa.eu/pub/conferences/shared/pdf/retpaym_150604/polasik_paper.pdf)
47. Poyser, O., (2017.): *Exploring the determinants of Bitcoin's price: an application of Bayesian Structural Time Series*, 2017. dostupno na: <https://arxiv.org/ftp/arxiv/papers/1706/1706.01437.pdf>
48. Rogina, N. (2017): *"Kriptovalute – česti pojmovi"*, Kriptovaluta.hr, 2017., dostupno na: <https://www.kriptovaluta.hr/izdvojeno/kriptovalute-cesti-pojmovi/>
49. Rogina, N. (2018.) *Što daje vrijednost kriptovalutama?*, Kriptovaluta.hr, 2018., dostupno na: <https://www.kriptovaluta.hr/tutorials/vodic-kroz-kriptovalute/3-dio-sto-daje-vrijednost-kriptovalutama/>
50. Rozga, A. (2009): *Statistika za ekonomiste*, Ekonomski fakultet Split, Split, 2009.
51. Sajter, D. (2018.): *Financijska analiza kriptovaluta u odnosu na standardne financijske instrumente*, Ekonomski fakultet u Osijeku, 2018., dostupno na: [https://bib.irb.hr/datoteka/930275.Interkat\\_2018\\_kripto.pdf](https://bib.irb.hr/datoteka/930275.Interkat_2018_kripto.pdf)
52. Samuelson, P.A., Nordhaus W.D. (2011): *"Ekonomija"*, Zagreb, MATE d.o.o., 2011.
53. Sašo, M. (2018): *"Bitcoin novčanik – korisne informacije o kripto novčanicima i Bitcoin sigurnost"*, Kriptomat.io, 2018., dostupno na: <https://kriptomat.io/hr/bitcoin-hr/najbolji-bitcoin-novcanici-i-sigurnost-kripto-novcanika/>
54. Segetlija, Z., Knego, N., Knežević, B., Dunković, D. (2011): *"Ekonomika trgovine"*, Zagreb, Novi informator d.o.o., 2011.
55. Seys, J., Decaestecker, K. (2016): *"The Evolution of Bitcoin Price Drivers: Moving Towards Stability?"*, University of Ghent, 2016., dostupno na : [https://lib.ugent.be/fulltxt/RUG01/002/273/510/RUG01-002273510\\_2016\\_0001\\_AC.pdf](https://lib.ugent.be/fulltxt/RUG01/002/273/510/RUG01-002273510_2016_0001_AC.pdf)

56. Vigna, P. (2017.): *Which Digital Currency Will Be the Next Bitcoin?*, The Wall Street Journal, 2011., dostupno na: <https://www.wsj.com/articles/which-digital-currency-will-be-the-next-bitcoin-1513679400>
57. Zelenika, R. (2000): *Metodologija i tehnologija izrade znanstvenog I stručnog djela*, 4. izdanje, Ekonomski fakultet Rijeka, 2000.
58. Živković, S. (2018): *"Blockchain tehnologija"*, završni rad, Sveučilište u Rijeci, 2018., dostupno na: <https://zir.nsk.hr/islandora/object/infri%3A289>

## **POPIS TABLICA I SLIKA**

### **POPIS TABLICA**

- Tablica 1: Sudionici rudarenja i njihove aktivnosti
- Tablica 2: 10 vodećih kriptovaluta po tržišnoj kapitalizaciji
- Tablica 3: Determinanta hashrate
- Tablica 4: Determinanta cijena zlata
- Tablica 5: Determinanta google trend
- Tablica 6: Determinanta broj transakcija po danu
- Tablica 7: Zavisne i nezavisne varijable u istraživanju
- Tablica 8: Deskriptivna analiza zavisnih varijabli
- Tablica 9: Deskriptivna analiza nezavisnih varijabli
- Tablica 10: Korelacija svih varijabli u istraživanju
- Tablica 11: Korelacija varijabli MODELA 1
- Tablica 12: Korelacija varijabli MODELA 2
- Tablica 13: Osnovni podaci o MODELU 1
- Tablica 14: Tablica ANOVA (MODEL 1)
- Tablica 15: Regresijski MODEL 1
- Tablica 16: Izbačena varijabla MODELA 1
- Tablica 17: Netipična zapažanja
- Tablica 18: Osnovni podaci o MODELU 2
- Tablica 19: Tablica ANOVA (MODEL 2)
- Tablica 20: Regresijski MODEL 2

### **POPIS SLIKA**

- Slika 1: Graf cijene Bitcoina
- Slika 2: Graf cijene Ethereuma
- Slika 3: Graf cijene XRP-a
- Slika 4: Odnos zavisne i nezavisnih varijabli (Letra)
- Slika 5: Odnos zavisne i nezavisnih varijabli (Polasik)

## SAŽETAK

Krajem prošlog desetljeća pojavile su se kriptovalute kao oblik digitalnih valuta. Nakon razvitka prve kriptovalute Bitcoina 2009. godine, do danas je razvijen veliki broj od čak 2194. Bitcoin je do danas ostao vodeća kriptovaluta po tržišnoj kapitalizaciji, te sa Ethereumom i Rippleom kao drugom i trećom kriptovalutom čini više od 70% ukupnog tržišta kriptovaluta. Istražen je utjecaj odabranih determinanti na zavisne varijable cijena Ethereum i cijena Ripplea. Regresijska analiza ekonomskih modela pokazala je blagi pozitivni utjecaj kod svih determinanti cijene Ripplea, dok se kod odabranih determinanti cijene Ethereum jedna varijabla pokazala statistički neznčajna.

**Ključne riječi:** kriptovalute, Ethereum, Ripple, determinante cijena

## SUMMARY

At the end of the last decade, cryptocurrencies appeared as a form of digital currency. Until today, Bitcoin has remained the leading position by market capitalization and with Ethereum and Ripple as the second and third cryptocurrencies by market capitalization hold up more than 70% of the total cryptocurrencies market. The influence of selected determinants on the dependent variables Ethereum price and Ripple price was studied. Regression analysis of economic models showed a slight positive influence on all determinants of Ripple prices, while one of the variables of Ethereum determinants proved statistically insignificant.

**Key words:** cryptovalute, Ethereum, Ripple, price determinants